

Lyhyen ajan ennusteet liikennetiedotuksen osana

Tiehallinnon selvityksiä 73/2001

Lyhyen ajan ennusteet liikennetiedotuksen osana

Tiehallinnon selvityksiä 73/2001

ISSN 1457-9871
ISBN 951-726-829-7
TIEH 3200719

Edita Prima Oy
Helsinki 2002

Julkaisua myy/saatavana:
Tiehallinto, julkaisumyynti
faksi 0204 22 2652
e-mail julkaisumyynti@tiehallinto.fi
www.tiehallinto.fi/julk2.htm



TIEHALLINTO
Liikenteen palvelut
Opastinsilta 12 A
PL 33
00521 HELSINKI
Puhelinvaihte 0204 22 150

TIIVISTELMÄ

Lyhyen ajan liikenne-ennusteita voidaan hyödyntää monissa liikenteen hallinnan toiminnoissa kuten automaattisissa liikenteen ohjausjärjestelmissä, alueellisessa liikenteen ohjauksessa ja liikennetiedotuksessa. Selvityksessä kartoitettiin kirjallisuustutkimuksen avulla, mihin vaiheeseen lyhyen ajan eli alle kahden tunnin päähän ulottuvien ennustemenetelmien tutkimuksissa ja käytännön soveltamisessa on edetty ja mitä kokemuksia on saatu ja mitä kehityssuuntia valittu. Lisäksi arvioitiin, millaiset mallit vaikuttavat lupaavimmilta liikenteen hallinnan palvelusovellusten kannalta. Selvityksellä luodaan pohjaa liikennetiedotuksen seuraavalle kehittämisvaiheelle Suomessa. Tästä syystä eri ennustemenetelmiä, niiden tarvitsemia lähtötietoja ja ennusteiden tarkkuutta tarkasteltiin ensisijaisesti liikennetiedotuksen näkökulmasta.

Kirjallista materiaalia aiheesta löytyi kohtuullisen helposti. Tutkimusta tehdään laajalti ja erilaisia ennustemalleja ja -menetelmiä on paljon kehitteillä, mutta päivittäisessä liikennetiedotuskäytössä olevia järjestelmiä tai toteutettuja palveluja ei löytynyt. Suurin osa läpikäydyistä lähteistä käsitteli malleja, joita on korkeintaan testattu oikealla liikennetiedolla. Mallien hyvyyden vertailu oli vaikeaa, koska raporteissa ennusteiden hyvyyttä on kuvattu hyvin erilaisilla virheen tunnusluvulla. Lisäksi mallin hyvyys voi yhden tunnusluvun avulla tarkasteltuna vaikuttaa kovin erilaiselta kuin toisen tunnusluvun avulla tarkasteltuna. Eri menetelmien käyttökelpoisuutta liikennetiedotukseen arvioitiin lähinnä sillä perusteella, kuinka suuren osan ajasta malli ennusti oikein. Liikennetiedotuksessa lyhyen ajan ennusteista on eniten hyötyä liikenteen ollessa ruuhkautunutta. Tärkeää on, miten hyvin malli toimii nimenomaan ruuhkatilanteissa. Tiedotuksen näkökulmasta ei ole syytä hyväksyä ennusteissa suurempaa virhemarginaalia ruuhka-aikana kuin muulloin. Ennusteiden tarkkuus on tiedotuspalvelussa kenties vielä tärkeämpää kuin liikenteenohjausjärjestelmissä, koska ennuste kerrotaan tienkäyttäjälle suoraan eikä tämä koe sitä vain välillisesti ohjausjärjestelmän toiminnan kautta.

Liikenne-ennustemenetelmät voidaan ryhmitellä neljään luokkaan: historiadataa ja tilastotietoa käyttävät menetelmät, neuroverkkoja ja/tai sumeaa logiikkaa mallinnuksessa hyödyntävät tekoälymenetelmät, simulointi- ja sijoittelumenetelmät sekä Kalman-suodattimeen perustuvat mallit. Puhtaat historiadataa käyttävät menetelmät ovat helppoja ottaa käyttöön ja tekevät ennusteen nopeasti, mutta ne eivät pysty reagoimaan liikennetilanteen yllättäviin muutoksiin. Simulointi- ja sijoittelumenetelmät soveltuvat erityisesti kaupunkialueille, joissa verkkonäkökulma on tärkeä ja kuljettajan reitinvalinnalla on suuri merkitys. Tekoälymenetelmät osaavat ennustaa liikennetilannetta muuttuvissakin olosuhteissa, jos mallin muuttujien valinta ja opettaminen on onnistunut. Eri ennustemenetelmät tarvitsevat osittain erilaisia lähtötietoja, mutta useimmiten mallit käyttävät lähtötietoinaan ajantasaista liikennemäärä-, nopeus ja varausastetietoa. Löytyi myös malleja, joissa on yhdistetty useita eri menetelmiä. Tämän perusteella ei voida sulkea pois mitään menetelmää vaan pikemminkin mallien kehittämisessä tulisi pyrkiä hyödyntämään eri menetelmien hyviä puolia. Menetelmien kehittämisessä ja kokeiluissa tulisikin jatkossa painottaa enemmän liikennetiedotuksessa ja alueellisessa ohjauksessa vaadittavaa verkkonäkökulmaa.

Keywords: road user information, predictions

ABSTRACT

Short-term traffic predictions can be used for many traffic management measures including automatic traffic control, area traffic management and road user information. This survey maps, with the help of a literature study, how far research work, prediction methods and their practical applications have proceeded. Also it explains what lessons have been learned and what directions of development have been chosen. The models were assessed in order to find out which seem to be the most promising for traffic management services. The purpose of this report is to provide a basis for future development of road user information in Finland. The input data requirements and prediction accuracy of various methods were therefore considered mainly from the traffic information point of view.

Literature concerning the subject could be fairly easily found. Research is going on, various prediction models and methods are developed but real information systems in operation and realised services were not found. The main part of the studied sources discussed models that had at most been tested with real traffic data. It was difficult to assess the performance of the models as it was described in the reports due to the different error parameters used. In addition, one parameter can give quite a different impression than another. The usability of various applications for traffic information was mainly assessed based on how long a model could predict correctly. Short-term predictions are most practical for information services during congestion. It is therefore important that the model performs well in congestion. From the information point of view there is no reason to tolerate larger margins of error during congestion. The accuracy of the predictions may be even more important for information than for control systems because the prediction is disseminated directly to road users.

Traffic prediction methods can be classified in four classes: methods making use of historic and statistic data, various artificial intelligence methods that make use of neural networks or fuzzy logic, simulation and traffic assignment methods and models based on Kalman filters. Methods making use of pure historic data are easy to implement and quickly calculate the prediction but they cannot react to surprising changes in the traffic situation. Simulation and traffic assignment methods suite especially well in urban environments where the network level point of view is important and the drivers' choice of route has great significance. Artificial intelligence methods are able to predict the traffic situation also in variable situations if the choice of variables and their learning has been successful. Various prediction methods partly require different input data but most models make use of real time traffic volume, speed and occupancy measurement. Also such models were found that make use of several methods. Based on this no method can be excluded, on the contrary the advantages of the various methods should be utilised for model development. In the future more emphasis should be on developing and testing the methods focusing on the network point of view required for traffic information and area traffic management.

The project has been granted European Community financial support in the field of Trans-European Networks – Transport.

ESIPUHE

Tiehallinto on tilannut Lyhyen ajan ennusteet liikennetiedotuksen osana – State of the Art –selvityksen Traficon Oy:ltä. Työn tavoitteena on kartoittaa tilannekuvaus maailmalla tehdyistä ja hyödynnetyistä kokemuksista lyhyen ajan liikenne-ennusteisiin liittyen.

Selvitys on tehty Traficon Oy:ssä kesällä 2001. Kirjallisuusselvityksen tekijänä toimi tekn. yo. Heli Mattila. Traficon Oy:ssä työhön osallistuivat myös DI Jari Oinas ja DI, DE Kristian Appel. Tiehallinnossa tutkimuksen etenemiseen ja valvontaan osallistuivat DI Sami Luoma, FK Jorma Helin sekä DI Martin Johansson. Tutkija, DI Satu Innamaa Teknillisestä korkeakoulusta osallistui selvityksen tekemiseen neuvonantajana ja mm. avustamalla kirjallisuuslähteiden etsinnässä.

Hanke on saanut Euroopan unionin liikenteen perusrakenteen kehittämiseen tarkoitettua TEN-T (Trans-European Networks – Transport) –rahoitusta.

Helsingissä 30. marraskuuta 2001

Tiehallinto

Liikenteen palvelut

Sisältö

1. JOHDANTO	9
2. TYÖN LÄHTÖKOHDAT JA TAVOITTEET	10
3. TUTKIMUSMENETELMÄ	11
4. LYHYEN AJAN ENNUSTEIDEN TARVE JA KÄYTTÖTARKOITUS	12
4.1 Ennusteiden tarve liikenteen hallinnan eri palveluissa	12
4.2 Vaatimukset liikenteen seurannalle	15
4.3 Tienkäyttäjän tarpeet	16
5. ENNUSTEMALLIEN LUOKITTELU	19
5.1 Menetelmien jaottelu	19
5.2 Tilastolliset menetelmät	19
5.3 Tekoälymenetelmät	20
5.3.1 Neuroverkot	20
5.3.2 Sumea logiikka	21
5.4 Simulointi- ja sijoittelumallit	21
5.4.1 Mikrosimulointi	21
5.4.2 Makrosimulointi	22
5.5 Kalman-suodattimeen perustuvat mallit	22
6. TUTKIMUSTULOSTEN ANALYSOINTI	23
6.1 Yleistilanne	23
6.2 Mallien tarvitsemat lähtötiedot	23
6.3 Ennusteiden arviointi	25
7. JOHTOPÄÄTÖKSET JA JATKOTOIMENPITEET	27

1. JOHDANTO

Yksi liikennetiedotuksen tärkeimmistä toiminnoista on ajantasainen sujuvuustiedotus eli jatkuva, linkkikohtainen tieto liikenteen sujuvuudesta. Tiedon avulla autoilija voi valita reittinsä välttyäkseen turhilta jonotuksilta ja viivytyksiltä sekä riskeiltä. Sujuvuustieto on erittäin hyödyllinen myös liikennekeskuksen päivystäjille heidän työssään sekä tiedottajille esimerkiksi paikallisradioasemilla.

Tienkäyttäjille palvelu on vieläkin hyödyllisempi, jos sitä täydentää ns. lyhyen ajan ennuste liikenteen sujuvuuden arvioidusta kehittymisestä lähiaikoina. Tällainen palvelu voi toimia kysyntää ohjaavana. Autoilija voi suunnitella reittinsä ja harkita tarvittaessa uudelleen lähtöaikaansa. Palvelun aikaperspektiivi saattaa vaihdella tiedotuksen tarkoituksesta ja alueellisesta laajuudesta johtuen. Palvelu voi noudattaa esimerkiksi samaa tarkkuustasoa kuin nykytilanteen sujuvuustiedotus aikatahtaimen ollessa 15 min – 2 tuntia. Valtateiden ruuhkissa lähinnä viikonloppuisin ja juhlapyhinä aikatahtain voi olla myös selvästi pidempi esimerkiksi 6 – 12 tuntia tai 24 tuntia ja tarkkuus vastaavasti karkeampi. Tässä selvityksessä on keskitytty ensiksi mainittuihin eli ennusteisiin, jotka ulottuvat korkeintaan noin kahden tunnin päähän nykyhetkestä.

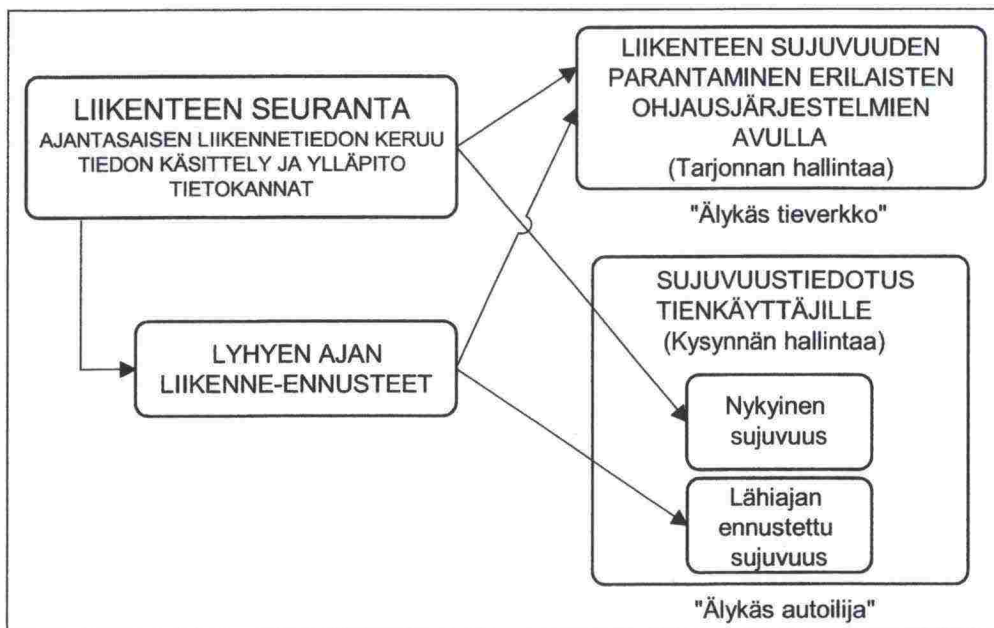
Lyhyen ajan ennusteen tuottaminen liikenteen sujuvuudesta vaatii mallintamista. Se voi tapahtua joko vertaamalla nykytilaa aikaisempiin tilanteisiin pelkästään silmämääräisesti tai perustua monimutkaisiin uusimpia mallinnusmenetelmiä (neuroverkot, sumea logiikka jne.) käyttäviin menetelmiin. Näiden välille mahtuu monenlaisia perinteisempiä mallinnusmenetelmiä.

Palvelua kehittämisessä tärkeä näkökulma on, miten ennustetietoa voidaan hyödyntää. Palvelusta on tehtävä tienkäyttäjälle helposti hyödynnettävä. Lisäksi on mietittävä, miten tiedotus vaikuttaa autoilijoiden käyttäytymiseen ja sitä kautta verkon toimintaan ja miten tämä voidaan huomioida mallinnuksessa ja tiedotuksessa.

2. TYÖN LÄHTÖKOHDAT JA TAVOITTEET

Maailmalla on tutkittu ja kokeiltu lyhyen ajan ennustemenetelmiä jo useita vuosia. Menetelmiä on kehitetty sekä sujuvuustiedotuksen että ohjauksen näkökulmasta. Tässä työssä keskitytään autoilijoille suunnattuun sujuvuustiedotukseen eli näkökulma on informaation tuottamisessa ja sitä kautta kysynnän ohjaamisessa (kuva 1). Työn tavoitteena on selvittää, kuinka pitkälle asiassa on muualla maailmassa edetty ja mitä kehityssuuntia on valittu. Tarkoituksena on selvittää, millaiset mallit vaikuttavat lupaavimmilta käytännön soveltamisen kannalta. Ennusteiden luotettavuuden lisäksi huomioitavia seikkoja ovat mm. mallin asettamat vaatimukset liikenteen seurannalle, mallin käyttämisen ja ylläpidon vaatimukset, mallin soveltaminen uusiin kohteisiin ja soveltuvuus erilaisten liikennetilanteiden ennustamiseen. Myös mallien asettamat laitevaatimukset lähinnä laskentatehon suhteen on huomioitava. Selvityksessä keskitytään erityisesti lyhyen ajan sujuvuustiedotuksen käytännön toteuttamiseen ja tuotteistukseen, joten vertailuun on otettu mukaan malleja, joiden toiminnasta käytännön tilanteissa on mahdollisimman paljon tietoa ja kokemuksia. Kiinnostuksen kohteena ovat myös tiedotuksella saavutettavat hyödyt sekä palvelun kustannukset.

Selvityksen tarkoitus on luoda pohja liikennetiedotuksen seuraavalle kehittämisvaiheelle Suomessa. Kun liikenteen ajantasainen sujuvuustiedotus saadaan liikenteen ajantasaisen seurannan myötä toimimaan kattavasti lähivuosina, on paljolti vain mallinnuksesta kiinni, milloin voidaan ryhtyä kokeilemaan lyhyen ajan sujuvuusennustetta palveluna. Tiehallinnon tavoitteena on, että liikennetilanneluokan lyhyen aikavälin ennusteet saataisiin kattavaan palvelukäyttöön viimeistään vuonna 2010 (Tiehallinto 2001a). Tavoitteeseen edetään tutkimustyön ja rajoitettujen kokeilujen kautta.



Kuva 1. Lyhyen ajan liikenne-ennusteiden hyödyntäminen osana liikenteen hallintaa. Tässä selvityksessä keskitytään tienkäyttäjille suunnattuun liikenteen sujuvuustiedotukseen.

3. TUTKIMUSMENETELMÄ

Selvitys on suoritettu kirjallisuustutkimuksena. Ensisijaisina tietolähteinä on käytetty IRRD-tietokantaa (International Transport Research Documentation) sekä ITS World Congress esitelmiä vuosilta 1997 – 2000. Hakusanoina on käytetty lähinnä ilmaisuja "short term"/"short time", "prediction"/"forecast" sekä "travel time information". Haku IRRD-tietokannasta tehtiin Tiehallinnon kirjastossa. Tiehallinnon kirjaston henkilökunta avusti tiedonhaussa opastamalla IRRD-tietokannan käytössä ja hankkimalla tietokannan avulla löydetyt lähteet selvitystyön tekijöiden käyttöön. Tutkimusta varten on myös haastateltu tutkija, diplomi-insinööri, Satu Innamaata, joka on perehtynyt erityisesti neuroverkkojen käyttöön lyhyen ajan liikenne-ennusteissa.

Oleellisimmiksi katsotut lähteet on listattu taulukkoon (liite 3), jossa kustakin lähteestä kerrotaan selvityksen kannalta tärkeimmät asiat tiivistetyssä muodossa. Mielenkiintoisimmista tapauksista on tehty kuvauskortit (liite 1), joissa kerrotaan tutkimuksesta ja sen tuloksista laajemmin.

4. LYHYEN AJAN ENNUSTEIDEN TARVE JA KÄYTTÖTARKOITUS

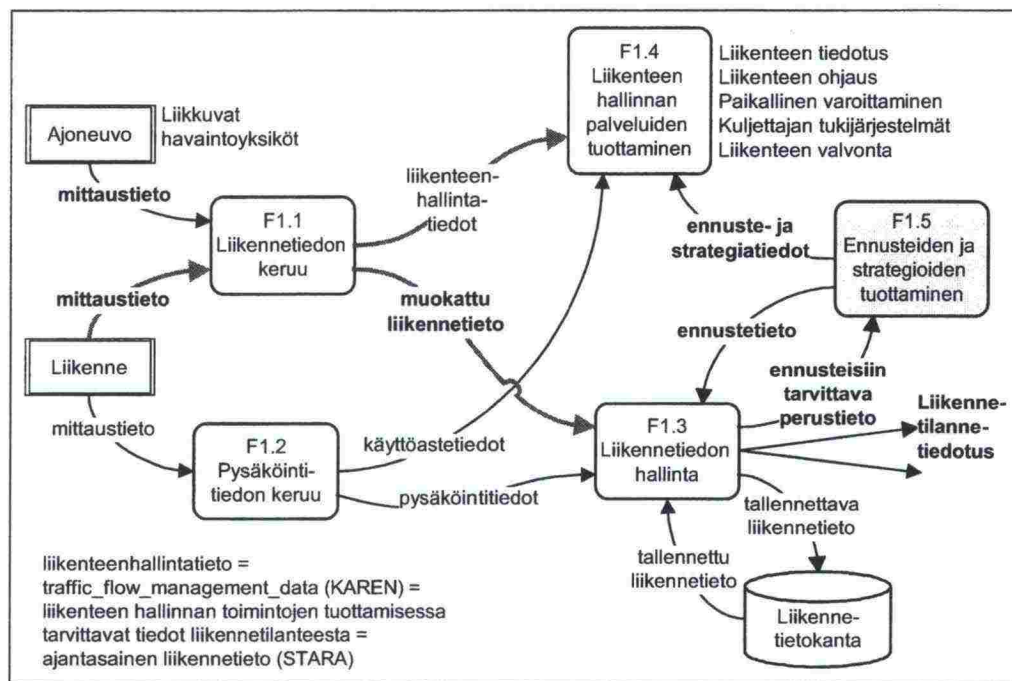
4.1 Ennusteiden tarve liikenteen hallinnan eri palveluissa

Tiehallinnon tärkeimmät liikenteen hallinnan toiminnot ovat tiedotus, ohjaus ja häiriön hallinta (Tiehallinto 2001b). Tärkeimpiin Tiehallinnolle asetettuihin liikenteen hallinnan päämääriin kuuluvat mm:

- Liikenneturvallisuuden parantaminen
- Matkustamisen ja kuljetusten varmuuden ja sujuvuuden turvaaminen
- Matkustus- ja kuljetuskysynnän mahdollisimman tehokas hoitaminen
- Infrastruktuurin mahdollisimman tehokas käyttö
- Liikennemuotojen yhteistoiminnan parantaminen
- Kansalaisten liikkumismahdollisuuksien turvaaminen
- Liikenteen ympäristöhaittojen vähentäminen
- Tietoyhteiskunnan edistäminen

Useimpien yllä mainittujen päämäärien voidaan katsoa hyötyvän lyhyen ajan liikenne-ennusteista. Saadessaan informaatiota liikenteen sujuvuuden ennakoidusta kehitymisestä lähitunteina, tienkäyttäjä voi mahdollisuuksiensa mukaan suunnitella reittinsä ja matkustusajankohtansa siten, että välttyisi ruuhkassa liikkumiselta. Matkustaminen tulee sujuvammaksi ja miellyttävämmäksi ja ajan käyttö tehostuu. Liikenne jakautuu tasaisemmin tieverkolle ja ruuhkahuiput tasoittuvat. Tämä tehostaa infrastruktuurin käyttöä ja vähentää liikenteen ympäristöhaittoja. Lyhyen ajan liikenne-ennusteet hyödyttävät sekä yksilöä että yhteiskuntaa.

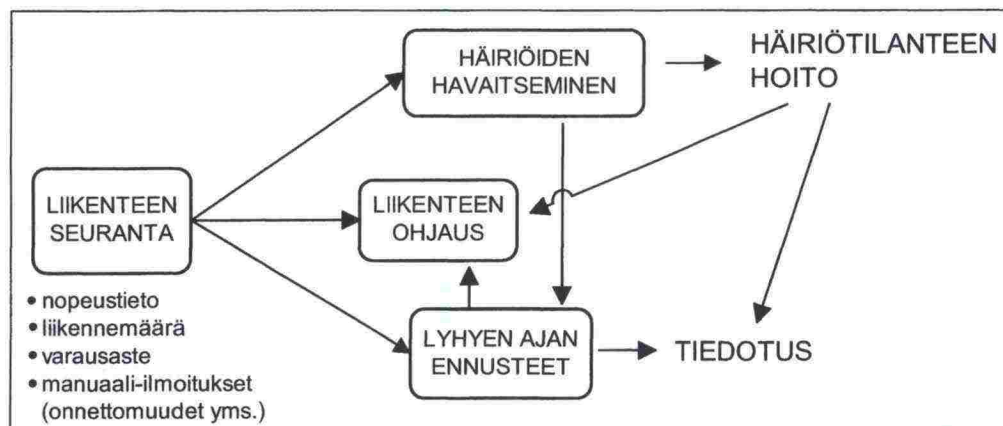
Kuvassa 2 on eurooppalaisen ITS -puitearkkitehtuurin (KAREN, European ITS Framework Architecture) pohjalta esitetty, miten liikenne-ennusteet ovat osa liikenteen hallinnan toimintoja.



Kuva 2. Liikenne-ennusteet osana liikenteen hallinnan toimintoja KAREN-arkkitehtuurin mukaan. Ennustamiseen liittyvät tietovirrat on merkitty lihavoituna.

Liikennetiedotus ei ole ainoa liikenteen hallinnan toiminto, joka tarvitsee lyhyen ajan ennusteita. Lyhyen ajan ennusteita voidaan hyödyntää automaattisissa liikenteen hallintajärjestelmissä kuten muuttuvassa liikenteen ohjauksessa ja opastuksessa sekä ruuhkavaroitussjärjestelmissä. Liikenteen alueellinen hallinta, jossa liikennettä ohjataan koko verkon kannalta optimaalisesti, voi vaatia myös liikennekeskuksen päivystäjän manuaalisia ohjaustoimia, joiden valinnassa päivystäjä voi hyödyntää lyhyen ajan ennusteita.

Myös häiriöiden hallinnassa voidaan hyödyntää lyhyen ajan liikenne-ennusteita. Häiriöiden hallinta muodostuu liikenteen tiedotuksesta ja ohjauksesta sekä eri tekijöiden välisestä yhteistyöstä häiriön havaitsemiseksi ja hoitamiseksi. Osana häiriöiden hallintaa on tiedotus häiriön luonteesta ja sen kestosta. Tässä voidaan hyödyntää lyhyen ajan ennusteita ennustamalla häiriöstä aiheutuneen ruuhkan vaikutus (esim. jonot) ja kesto. Lyhyen ajan ennusteiden käyttöä häiriöiden hoidossa havainnollistaa kuva 3.



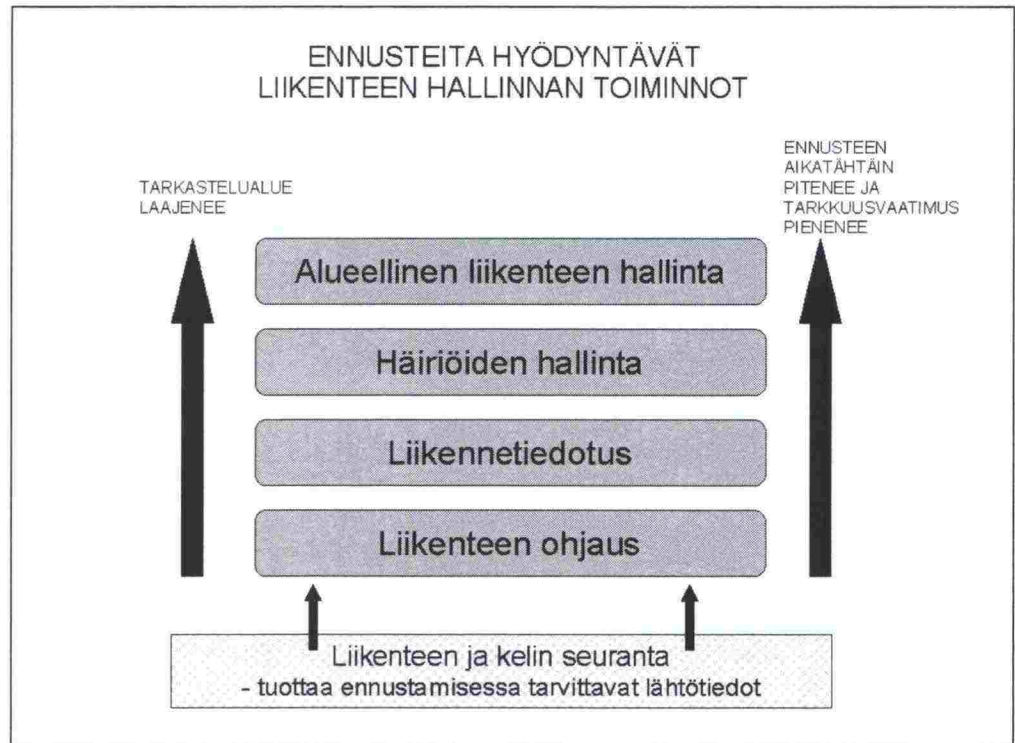
Kuva 3. Lyhyen ajan ennusteiden hyödyntäminen häiriötilanteiden hoitamisessa

Suuresta kuormitusasteesta johtuvan ruuhkan ennakoiminen edellyttää liikennevirran sujuvuutta kuvaavien liikennetietojen (nopeus, liikennemäärä jne.) keruuta. Liikennevirta käyttäytyy ruuhkatilanteissa eri tavalla kuin normaaleissa olosuhteissa. Sujuvuuden heikkeneminen taas ennakoi ruuhkan syntymistä. Automaattisten ruuhkavaroitusta ja muiden automaattisten liikenteen ohjausjärjestelmien keräämää tietoa liikennevirran käyttäytymisestä voidaan hyödyntää lyhyen ajan liikenne-ennusteiden tekemisessä.

Liikennetiedotuspalvelussa tarvitaan ensisijaisesti tietoa nopeuden ennustetusta kehityksestä. Keskinopeuden perusteella määritetään liikennetilanneluokka (liikenne sujuvaa, jonoutunutta, hidasta, pysähtelee tai seisoo) (Tiehallinto 2001a), joka esitetään tienkäyttäjille esimerkiksi värikoodattuna karttana. Liikennetilanneluokituksista saatetaan kehittää siten, että siinä otetaan nopeuden lisäksi huomioon myös liikennemäärä, jolloin liikennemääräennusteiden merkitys kasvaa. Linkki- tai väyläkohtainen ennustettu matka-aikatieto on myös hyödyllistä autoilijalle, joka voi valita kahden tai useamman reitin välillä. Liikennetiedotuksen kannalta on tärkeää, että malli osaisi tunnistaa erityisesti tilanteet, joissa ruuhka on syntymässä ja vastaavasti purkautumassa. Liikenteestä mitattavissa suureissa saattaa olla satunnaista vaihtelua, joka mallin tulisi osata erottaa todellisesta liikennetilanteen muuttamisesta.

Häiriöiden hallinnan ja liikenteen ohjauksen kannalta tärkeimpiä ennustesuureita ovat liikennemäärä ja liikennevirran keskinopeus. Automaattisissa liikenteen ohjausjärjestelmissä (esim. liikennevalot) ohjelmanvalinta perustuu yleensä liikennemäärään. Nykyisin ohjelman valinta tapahtuu pääsääntöisesti kellonajan perusteella tai tietyn mittausjakson (yleensä 5...15 min) toteutuneeseen liikennemäärään eli historiatietoon perustuen. Liikennemääräennusteen avulla voitaisiin ohjelman vaihto ajoittaa mahdollisimman oikea-aikaisesti. Häiriöiden hallintaan kuuluu usein liikenteen ohjaaminen vaihtoehtoiselle reitille esim. onnettomuuden tai tietyön takia. Lyhyen ajan liikennemääräennustetta voidaan käyttää vaihtoehtoisten reittien suunnitteluun tarkastelemalla reittien kuormitusta häiriön takia lisääntyneellä liikennemäärällä.

Kuvassa 4 on esitetty ennusteita hyödyntävät liikenteen hallinnan toiminnot. Eri toiminnoilla on erilaiset aikajänteet. Liikenteen ohjaus, joka keskittyy usein vain yhteen väylään tai liittymään, tarvitsee nopeasti tuotettuja ja tarkkoja sekä paikallisia ennusteita. Liikennetiedotuksessa aikatahtain on hie-
man pidempi ja tarkastelualue laajempi. Häiriöiden hallinnassa ja alueelli-
sessa liikenteen hallinnassa tarkastellaan vielä suurempia kokonaisuuksia
kuin liikenteen ohjauksessa ja liikennetiedotuksessa.



Kuva 4. Lyhyen ajan ennusteita hyödyntävät liikenteen hallinnan toiminnot.

4.2 Vaatimukset liikenteen seurannalle

Liikenteen hallinnan toiminnot vaativat liikenteen ajantasaista seuranta. Liikenteen hallinnan palvelut tarvitsevat tietoa sekä pysyvistä että muuttuvista seikoista tieliikennejärjestelmässä. Erityisen tärkeitä ovat ajantasaiset tiedot liikenteestä ja häiriötilanteista kuten onnettomuuksista ja tietöistä. Myös säästä, kelistä ja kunnossapidon tilanteesta tarvitaan ajantasaista tietoa. Eri liikenteen hallinnan toiminnot tarvitsevat osittain erilaisia lähtötietoja. (Tiehallinto 2001b)

Liikenteen seuranta voidaan jakaa automaattiseen ja manuaaliseen seurantaan. Automaattinen seuranta tapahtuu erilaisilla kiinteillä mittauslaitteilla tai liikkuvilla antureilla. Manuaaliseuranta taas tarkoittaa erilaisia ihmisten liikenteestä tekemiä havaintoja. (Tiehallinto 2001a)

Liikenteen historia- ja tilastotietoja tarvitaan mm. liikenteen yleisen kehityksen seuraamiseen ja pitkän aikavälin ennusteiden laatimiseen. Tiedot kerätään Tiehallinnon LAM-järjestelmällä (liikenteen automaattinen mittausjär-

jestelmä) ja muilla Tiehallinnon vuosittain tekemillä liikennelaskennoilla. Lisäksi erilaiset liikenteen ohjaus- ja valvontajärjestelmät keräävät omiin tietokantoihinsa tilastotietoja. (Tiehallinto 2001a)

Historia- ja tilastotietoja käytetään useissa menetelmissä lyhyen ajan ennusteiden laatimiseen. Tilastolliset menetelmät tarvitsevat tilastotietoa lähtötiedokseen. Tilastotieto voidaan luokitella päivätyypin (arki, lauantai, pyhä) ja vuodenajan mukaan, mutta yhdeksi luokittelevaksi tekijäksi voidaan ottaa myös sää ja keli. Erilaiset vuosittain toistuvat paljon yleisöä keräävät tapahtumat tulee myös huomioida. Myös mm. neuroverkkomenetelmissä tarvitaan tilannekirjaston tietoja verkon opetukseen.

Ajantasaista liikennetietoa tarvitaan päivittäisessä liikenteen hallinnassa kuten valo-ohjauksen toiminnan säätelyssä ja liikennetilannetiedottamisessa. Ajantasainen liikenteen seuranta edellyttää, että kerätyt liikennetiedot ovat hyödynnettävissä muutaman minuutin viipeellä. LAM-järjestelmän ja liikenteen ohjaus- ja valvontajärjestelmien keräämää tietoa voidaan hyödyntää myös ajantasaisen liikennetiedon keruussa. (Tiehallinto 2001a)

Lyhyen ajan ennustemenetelmät tarvitsevat paljon ajantasaista liikennetietoa. Ennusteissa tarvitaan useimmiten tietoja liikennemäärästä, ajoneuvojen nopeudesta sekä ilmaisimen varausasteesta.

Liikenteen sujuvuustietoa voidaan saada sekä piste- että linkkimittauksesta. Pistemittauksessa liikenteen sujuvuus määritetään yhdessä tai useammassa seurantalinkin pisteessä kerättyjen tunnuslukujen avulla. Pistemittauksen tuottamien tietojen oletetaan kuvaavan koko linkin tilaa, jolloin virhepäätelmien riski on olemassa. (Tiehallinto 2001a) Luotettavuutta voidaan parantaa lyhentämällä mittauspisteiden välimatkaa. Pistemittauksissa tiedot kerätään nykyisin pääasiassa induktiosilmukoilla. Lyhyen ajan ennusteet saattavat edellyttää enemmän mittauspisteitä kuin pelkkä nykytilanteen seuranta.

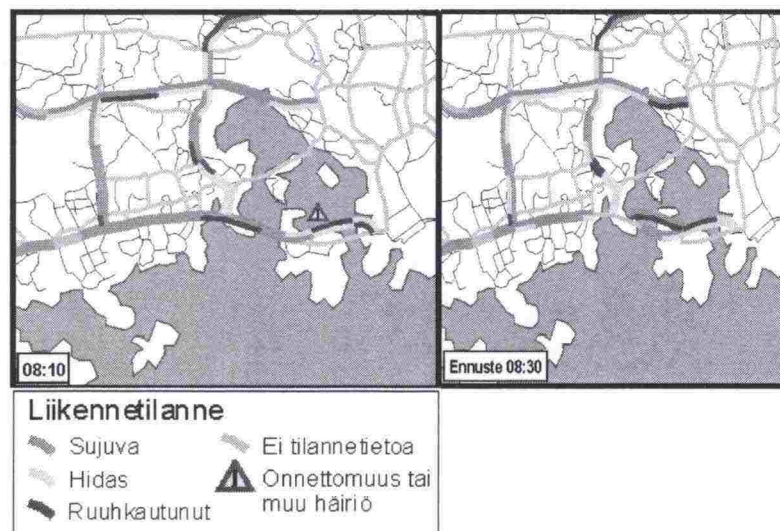
Linkkimittauksissa tunnistetaan yksittäisiä ajoneuvoja tai niiden ominaisuuksia seurantalinkin päissä ja linkin keskinopeus lasketaan näistä tiedoista. Liikenteen seuranta tapahtuu automaattisen ajoneuvon tunnistamisen kuten rekisterikilpien tunnistamisen avulla. Seurantalinkin keskinopeustieto reagoi muutoksiin tasaisemmin kuin pistetieto. Tämän voidaan olettaa helpottavan sujuvuuden lyhyen aikavälin ennustettavuutta. Ongelmia tuottaa kuitenkin se, että mitä enemmän matkanopeus laskee tai mitä pidempi seurantalinkki on, sitä enemmän matka-aikatieto viivästyy. (Tiehallinto 2001a)

Muita liikenteen seurantaan käytettäviä menetelmiä, joiden keräämiä tietoja voitaisiin käyttää lyhyen ajan ennusteiden tekoon, ovat mm. videokamerat, infrapunailmaisimet, tutkailmaisimet, GSM-paikannus ja anturiajoneuvot. (Tiehallinto 2001a)

4.3 Tienkäyttäjän tarpeet

Sujuvuustiedottamisessa tulee erityisesti huomioida tienkäyttäjän tarpeet ja sopiva tiedon esitysmuoto. Suurimmat vaikutukset liikenteen sujuvuuteen saadaan aikaan, kun autoilija saa informaation mahdollisimman aikaisessa vaiheessa, jolloin matkan ajankohtaa voi vielä muuttaa. Häiriötilanteessa on

lisäksi tärkeää, että tienkäyttäjä saa tiedon häiriöstä sekä sen havaituista ja odotettavissa olevista vaikutuksista mahdollisimman pian häiriön havaitsemisen jälkeen. Liikenteen sujuvuuden ennakoitu kehittyminen on mahdollista esittää nykytilanteen rinnalla esim. internetissä värikoodattuna karttana. Tästä on esimerkki kuvassa 5. Värikoodatulla kartalla liikennetilanneluokka esitetään linkeittäin ja ajosuunnittain eri väreillä. Liikennetilanneluokitus perustuu liikennevirran keskinopeuden ja vapaan virran keskinopeuden suhteeseen (Liikenteen seurannan valtakunnallinen esiselvitys Tiehallinto 2001a). Autoilijoille voitaisiin myös kertoa liikennetilanteesta tarkemmin ilmoittamalla kunkin linkin keskinopeus ja/tai matka-aika. Liikennetilanneluokka hyödyttää etenkin autoilijoita, jotka eivät tunne seutua eivätkä osaa arvioida tieosien normaalia matka-aikaa. Seudulla päivittäin liikkuvat autoilijat saattaisivat myös kokea keskinopeus- ja matka-aikatiedotuksen hyödyllisenä.



Kuva 5. Värikoodattu kartta nykyhetken liikennetilanteesta (vas.) ja ennustetusta liikennetilanteesta (oik.).

Internetissä esitetty informaatio on käytettävissä matkaa suunniteltaessa ja sen ajoituksesta päätettäessä. Liikennetilanne saattaa muuttua nopeasti, joten myös matkalla oleva autoilija tarvitsee ajantasaista tietoa liikenteen sujuvuudesta, voidakseen vaihtaa reittiään ja välttää näin ruuhkan. Matkalla olevalle autoilijalle informaatiota voidaan jakaa radion välityksellä, muuttuvilla tiedotustauluilla tai henkilökohtaisesti esim. kännykän avulla. Matkan aikana annetun informaation on oltava yksinkertaista ja selkeää, jotta autoilijan on helppo tehdä päätös mahdollisesta reitin vaihtamisesta. Autoilijalle voidaan myös antaa suosituksia reitinvalinnasta. Informaatiosta on eniten hyötyä, kun se annetaan riittävän ajoissa, jolloin autoilija voi vielä vaihtaa reittiään ja välttää ruuhkan (Lind 2000).

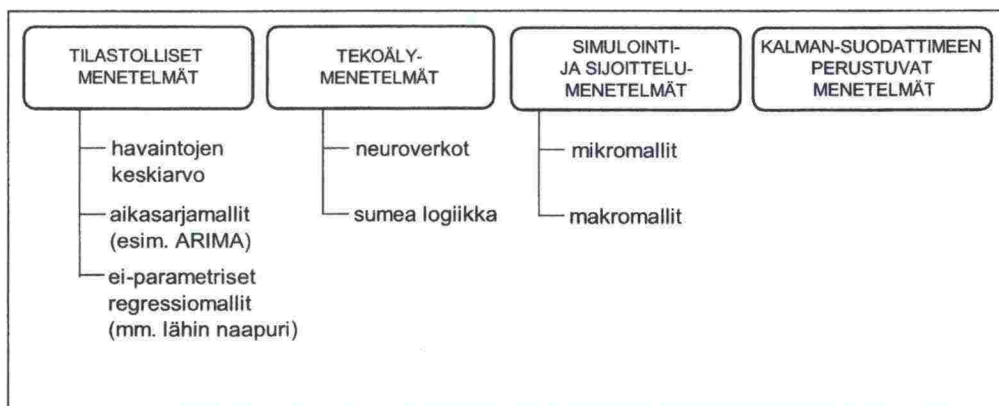
Erittäin tärkeää on, että annettu informaatio on luotettavaa. Tämä on tärkeää heti kun palvelu otetaan käyttöön. Jos autoilija kokee saavansa virheellistä informaatiota, hänen luottamuksensa järjestelmään heikkenee oleellisesti. Voidaan kuitenkin olettaa, että aliarvoitu matka-aika on tienkäyttäjän kannalta haitallisempaa kuin hieman yliarvoitu matka-aika. Autoilija ärsyyntyy ruuhkasta vielä enemmän, jos hän on saanut virheellistä informaatiota, jonka

mukaan liikennetilanne olisi todellisuutta sujuvampi. Tielaitoksen Ruuhkaisuuden kokeminen ja liikennetilannetiedottaminen –tutkimuksessa (1996) puolet kuljettajista koki ajomukavuuden vähentyneen, kun liikenteen keskinopeus oli pienentynyt noin 8 %. Yksilön kokeman haitan lisäksi virheellinen informaatio aiheuttaa myös yhteiskuntataloudellisia kustannuksia, jos autoilija valitsee hitaamman ja ruuhkaantuneemman reitin. Tiehallinnon korkeimman laatutason mukaan ennustetuissa matka-ajoissa hyväksytään 10% virhemarginaali. Matalimmalla laatutasolla virhemarginaali on 20% (Tiehallinto 2001 b).

5. ENNUSTEMALLIEN LUOKITTELU

5.1 Menetelmien jaottelu

Ennustemallit voidaan jakaa historiadataa ja tilastoja käyttäviin malleihin, tekoälymalleihin, simulointi- ja sijoittelumalleihin ja Kalman-suodattimeen perustuviin malleihin (Innamaa 2001). Ennustemenetelmät on esitetty kuvassa 6. Jako ei kuitenkaan ole yksiselitteinen ja useat mallinnusmenetelmät yhdistelevät eri menetelmiä. Tästä esimerkkinä voidaan mainita mallit, jotka etsivät historiadatasta eli tilannekirjastosta samankaltaisia liikennetilanteita SOM-neuroverkon (self-organizing map, itseorganisoiva kartta) avulla. Joitakin menetelmiä ei voida luokitella kuuluvaksi mihinkään näistä menetelmätyypeistä.



Kuva 6. Ennustemenetelmien luokittelu.

5.2 Tilastolliset menetelmät

Historiatietoa käyttävät mallit perustuvat tilastoiuihin liikenteen kausi-, viiko- ja tuntivaihteluihin.

Tietokannan havaintojen keskiarvoon perustuva malli käyttää yksinkertaisesti aikaisempien liikennemäärien keskiarvoa lähitulevaisuuden liikenteen ennustamiseen. Haluttaessa ennustaa liikennemäärää ajan D kuluttua, ennusteen $Q(t+D)$ hetkellä t estimoidaan siis olevan yksinkertaisesti $Q_{\text{hist}}(t+D)$. Tilastoidut liikennetilanteet voidaan ryhmitellä esim. viikonpäivän tai sään ja kelin mukaan, jolloin esim. sateisen maanantain ennusteeseen huomioidaan edellisten sateisten maanantaiden toteutunut liikenne. Menetelmä on helppo ottaa käyttöön ja ennuste voidaan laskea nopeasti. Koska malli perustuu tilastoiuihin liikenteen vaihteluihin, se ei kykene vastaamaan keskimääräisestä poikkeaviin tilanteisiin. (Innamaa 1999)

Tilastolliset aikasarjamallit, kuten autoregressiiviset integroidut liukuvan keskiarvon mallit (ARIMA-mallit), perustuvat matemaattiseen malliin, jonka

avulla pyritään selittämään aikasarjadataan aikaisempaa käyttäytymistä ja ennustamaan liikennettä sen perusteella. ARIMA perustuu keskeytymättömään datasarjaan, jonka saaminen on kuitenkin usein hankalaa. Tästä syystä aikasarjamalli ei sovellu kovin hyvin laajamittaisiin sovelluksiin. (Innamaa 1999) Aikasarjamalleja käytettäessä on tärkeää tunnistaa eri tyyppiset vaihtelut aikasarjassa. Näitä vaihteluja ovat satunnaisvaihtelu, jaksollinen vaihtelu ja trendit (Sundberg ym. 2000). On tärkeää, että malli erottaa satunnaisvaihtelun todellisesta liikennetilanteen muuttumisesta. Jos eri liikennevirroilla on erilaiset selittävät tekijät, voidaan kullekin kehittää oma aikasarjamallinsa ja yhdistää näiden tulos (Sundberg ym. 2000).

Ei-parametrisessa regressiomallissa yritetään etsiä tilannekirjastosta aikaisempien havaintojen joukkoja, jotka ovat vastaavanlaisessa tilassa kuin järjestelmä ennustehetkellä. Ei-parametrisistä regressiomenetelmistä ennustamisessa on usein käytetty **lähin naapuri** -menetelmää. Menetelmässä naapurit on määritelty niinä k:nä havaintona, jotka muistuttavat eniten järjestelmää ennustehetkellä. Halutun tilanteen estimaatti määritellään laskeamalla naapureista keskiarvo. Menetelmän hyvänä puolena on se, että se ei tarvitse ennako-oletuksia olemassa olevista riippuvuussuhteista. Naapureiden löytäminen voi kuitenkin olla hankalaa. Lähin naapuri -menetelmä sopii kohteisiin, joissa liikennetilanne voidaan kuvata yhdellä muuttujalla, jonka perusteella naapurit valitaan. Jos muuttujia tarvitaan enemmän, tilannekirjastossa olevien havaintojen luokitteluun ja naapureiden löytämiseen soveltuu paremmin itseorganisoituva kartta (self-organizing map) eli SOM-neuroverkko. (Innamaa 1999)

5.3 Tekoälymenetelmät

Tekoälymenetelmiä ovat erilaiset neuroverkkomallit ja sumeaa logiikkaa käyttävät menetelmät.

5.3.1 Neuroverkot

Neuroverkkojen ideana on jäljitellä ihmisen oppimis- ja päättelyprosessia matemaattisesti (Hintikka, Göös). Neuroverkoilla yritetään mallintaa biologisia neuroneja ja näiden välisiä yhteyksiä (Sundberg ym. 2000). Neuroverkko koostuu joukosta "keinotekoisia hermosoluja" eli solmuja, jotka on liitetty toisiinsa. Tietojen käsittely tapahtuu solmuja toisiinsa yhdistävien liitosten välityksellä. Neuroverkolle opetetaan asioita syöttämällä sille esimerkkejä analysoitavista tilanteista. Neuroverkko oppii siis esimerkeistä yleistämällä, siihen ei suoraan ohjelmoida tiettyjä syötteitä vastaavuuksineen. Oppiminen tapahtuu solmujen välillä sijaisevien liitosten voimakkuuksissa tapahtuvina muutoksina. Tapa, jolla nämä muutokset tapahtuvat on ohjelmoitu. (Honkela) Opettaminen tulee lopettaa ajoissa, ettei ylioppimista tapahdu, sillä verkon tulee osata yleistää muuttujien väliset riippuvuudet (Innamaa 1999).

Neuroverkko on osoittautunut tehokkaaksi menetelmäksi monimutkaisten epälineaaristen riippuvaisuuksien esittämiseen (Innamaa 1999). Neuroverkot sopivat sellaisten ilmiöiden mallintamiseen, jotka ovat moniulotteisia, kokonaisvaltaisia ja jatkuvia (Honkela). Niillä on hyvä virheensietokyky eivätkä ne ole herkkiä lähdetietojen epämääräisyydelle (Juutilainen). Neuroverkkojen

opetusprosessi on monimutkainen, mutta opetuksen jälkeen ne ovat käytössä yksinkertaisia. Monimutkainen neuroverkko vaatii myös kohtuullisen paljon laskentatehoa opetusvaiheessa. Neuroverkkoa on opetettava riittävästi ja sen testaamiseen sekä validointiin tulee kiinnittää huomiota. Siirrettäessä verkkoa alkuperäisestä paikasta toiseen, on se opetettava uudelleen, jotta se oppisi uuden ongelman erityispiirteet. (Innamaa, Pursula 2000)

Lyhyen ajan ennustamisessa käytetään ennusteen syötetietoina esim. matka-aikaa ajoneuvon lähtöhetkellä ja tiejaksolla olevien ajoneuvojen lukumäärää. Opetusjoukon tulee olla riittävän laaja ja ruuhkatilanteiden ennakoimiseksi verkkoa täytyy opettaa riittävän laajalla ruuhka-ajan aineistolla. Yleisimmin liikennetekniikassa käytettyä neuroverkkoa opetetaan vastavirta-algoritmeilla. (Innamaa 1999)

5.3.2 Sumea logiikka

Sumea logiikka mallintaa ihmisen ajattelun ja toiminnan epävarmuutta ja epätasaisuutta (Tekes). Sumean logiikan mukaan kaikki tilanteet eivät ole mustavalkoisia joko tai –tilanteita (Pesonen). Sumeassa joukko-opissa erilaisten tilanteiden on mahdollista kuulua tiettyyn joukkoon vain osittain ja useampaan joukkoon yhtä aikaa. Perinteisesti ajatellenhan tilanne joko kuuluu johonkin luokkaan tai sitten ei. Jäsenyysaste kuvaa sitä, kuinka paljon jokin tilanne kuuluu johonkin tiettyyn luokkaan. Jäsenyysaste voi saada esimerkiksi arvoja 0...1. Jäsenyysaste 0 vastaa täyttä joukkoon kuulumattomuutta ja 1 täydellistä kuulumista. Jäsenyysaste tältä väliltä tarkoittaa, että tilanne kuuluu joukkoon osittain. (Hintikka, Göös) Sumeaa logiikka voi verrata todennäköisyyslaskentaan, jossa jonkin tapahtuman todennäköisyys on myös välillä 0...1. Sumean logiikan hyviä puolia ovat vaihtelevan toiminnan mallintaminen ja hyvä häiriön sietokyky. Ongelmana on oikean sääntöjoukon löytäminen ja testaaminen. (Pesonen) Sumeaa logiikkaa käytetään usein neuroverkkojen yhteydessä.

5.4 Simulointi- ja sijoittelumallit

Simulointimallit jaetaan mikroskooppisiin ja makroskooppisiin simulointimalleihin.

5.4.1 Mikrosimulointi

Mikrosimuloinnissa mallinnetaan yksittäisiä ajoneuvoja ja näiden toimintoja tieverkolla. Jokaisella ajoneuvolla on yksilölliset ominaisuudet ja reitti verkolla. Tämän takia mikrosimulointimalleilla voidaan hyvin arvioida lyhytaikaisten liikenteen hallinnan toimintojen (esim. valo-ohjauksen säädöt) vaikutuksia liikenteen sujuvuuteen. Haittapuolena on, että mikrosimulointimallit vaativat paljon tietoa ja tietokonekapasiteettia. Mikrosimulointiin perustuvia malleja ei olekaan maailmalla laajamittaisessa käytössä. (Milne 2001) Teknillisessä korkeakoulussa on kehitteillä mikrosimulointiin perustuva sovellus (DigiTraffic), jonka periaatteena on luoda ajantasaisia ja ennustavia koko-

naismalleja liikenneolosuhteista perustuen saatavilla olevaan ajantasaiseen mittaustietoon.

5.4.2 Makrosimulointi

Makroskooppisessa simuloinnissa liikennettä mallinnetaan yhtenä kokonaisuutena makroskooppisten ominaisuuksien kuten liikennemäärän ja -tiheyden sekä nopeuden avulla. Nämä mallit ovat luonteeltaan staattisia ja siksi niiden käyttäminen lyhyen ajan ennustuksissa sisältää paljon rajoituksia. (Milne 2001)

Sijoittelua voidaan käyttää osana makroskooppisia simulointimalleja liikennemäärien määrittämiseen. Sijoittelu- ja simulointimallit vaativat dynaamisen lähtöpaikka-määräpaikka- eli OD-matriisin lähtötiedoikseen. Lisäksi mallit tarvitsevat tietoa liikenneverkon rakenteesta, liikennevaloista ym. Ennusteprosessi on iteratiivinen. Simulointivaiheen tavoitteena on tuottaa tietoa linkkien matka-ajoista kulloisellakin liikenteellä. Sijoitteluvaiheen tavoitteena taas on sijoitella matkat liikenneverkolle. Sijoittelu- ja simulointimalli on isoilla verkoilla hidas ja raskas ja vaatii paljon laskentatehoa. (Innamaa, Pursula 2000). Tämän takia sijoittelu- ja simulointimallit eivät kovin hyvin sovellu dynaamisen liikenteenohjauksen tarpeisiin. Liikennetiedotuspalvelussa ajatähtäin on kuitenkin ohjausta pidempi eikä ennusteen tarvitse syntyä yhtä nopeasti. Sijoittelu- ja simulointimalli sopii käytettäväksi silloin, kun verkkonäkökulma on tärkeä ja kuljettajan reitinvalinnalla on suuri merkitys (Innamaa, Pursula 2000). Nämä asiat korostuvat etenkin liikenteen ennustamisessa ja tiedotuksessa kaupunkialuilla, joilla on useita eri reittivaihtoehtoja.

5.5 Kalman-suodattimeen perustuvat mallit

Kalman suodatus on rekursiivinen menetelmä, joka estimoi dynaamisen systeemin hetkellisen tilan satunnaisia virheitä (valkoista kohinaa) sisältävien mittausten perusteella (Schulz, Werwats 2001). Kalman suodattimen perusajatus on se, että haluttujen muuttujien arvot ennustetaan aiempaan informaatioon perustuen siihen hetkeen asti, kunnes uusi mittaustulos on käytössä. Kun uusi mittaustulos saadaan käyttöön, muuttujien estimaattia korjataan mittauksen ja ennusteen väliseen erotukseen verrannollisena. (Karvonen ym. 1982) Kalman suodatinta voidaan pitää klassisen pienimmän neliösumman laajenuksena (Holma 1991). Kalman suodatin suodattaa liikennemittauksen reaaliajassa, on joustava, kalibroi itse itsensä, siinä ei ole stationaarisuusoletuksia ja se pitää sisällään häiriöiden havainnoinnin (Innamaa 1999).

6. TUTKIMUSTULOSTEN ANALYSOINTI

6.1 Yleistilanne

Menetelmiä ja malleja lyhyen ajan liikenne-ennusteiden tekemiseen on tutkittu ja kehitelty maailmalla jo useita vuosia. Aihe kiinnostaa tutkijoita ja erilaisia ennustemenetelmiä on paljon kehitteillä ja tutkimustyötä aiheen ympärillä tehdään. Toteutettuja ja liikennetiedotuskäyttöön vietyjä palveluja ei ole kuitenkaan tässä selvitystyössä löytynyt. Alalla ei tunnu olevan tiettyä selkeää kehityssuuntaa, vaan eri tutkijat ovat keskittyneet erilaisiin ennustemenetelmiin. Ehkä yleisimpiä tutkimuksen kohteena olevia menetelmiä ovat kuitenkin neuroverkkomenetelmät ja erilaiset historiatietoa käyttävät menetelmät. Tutkimusta tehdään erityisesti Keski-Euroopassa (mm. Saksa, Hollanti), USA:ssa, Australiassa ja Japanissa sekä Koreassa. Suomessa on viime vuosina tutkittu lyhyen ajan liikenne-ennusteiden tekemistä neuroverkkojen avulla.

Vaikka todellisessa tiedotuspalvelukäytössä olevia järjestelmiä ei löytynytkään, on lähes kaikkia tässä selvityksessä läpikäytyjä ennustemenetelmiä testattu oikealla liikennetiedolla. Testialueiden koko ja testausaika vaihtelivat suuresti (muutamasta tunnista useisiin kuukausiin). Joissakin tapauksissa testaaminen on tehty jollakin simulointiohjelmalla. Useimmat menetelmät sopivat moottoritie liikenteen ennustamiseen, verkkonäkökulma on mukana harvemmin. Useimmiten menetelmissä ennustetaan linkkien matka-aikaa, keskinopeutta ja/tai liikennemäärää. Suurimmat haasteet malleissa liittyvät ruuhkaliikenteen ennustamiseen ja etenkin ruuhkan alkamisen ja purkautumisen havaitsemiseen. Ruuhkattomassa tilanteessa ennustaminen on helppoa. Tienkäyttäjän ja tiedotuspalvelun kannalta juuri ruuhkatilanteiden ja liikenneolojen muutoskohtien havaitseminen olisi erityisen tärkeää.

6.2 Mallien tarvitsemat lähtötiedot

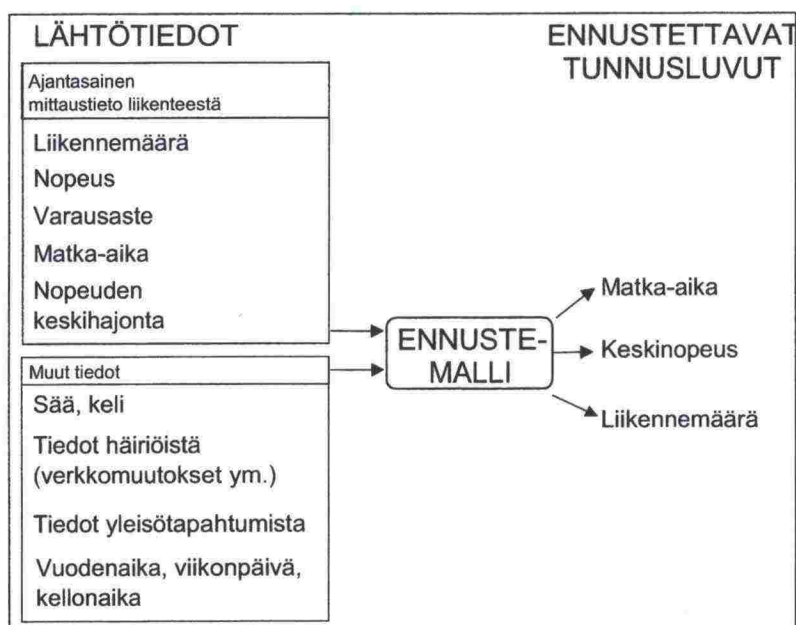
Erilaiset lyhyen ajan ennustemenetelmät tarvitsevat osittain erilaisia lähtötietoja. Useimmiten menetelmät käyttävät lähtötietoinaan kuitenkin liikennemäärää, keskinopeutta ja varausastetta. Useimmissa lähteissä ajantasaisen liikennetiedon keräämiseen on käytetty induktiosilmukoita. Muita menetelmiä olivat mm. automaattinen ajoneuvontunnistus ja anturiajoneuvot.

Taulukkoon 1 on koottu läpikäytyjen kirjallisuuslähteiden perusteella eri ennustemenetelmien yleisesti tarvitsemia lähtötietoja. Taulukossa on ++ -merkinnällä osoitettu useimmiten käytetyt lähtötiedot, ja + -merkinnällä harvemmin käytetyt.

Taulukko 1. Erilaisten ennustemenetelmien tarvitsemia lähtötietoja. ++ tarkoittaa useimpien lähteiden käyttämää lähtötietoa ja + joidenkin lähteiden käyttämää lähtötietoa.

ENNUSTEMENETELMÄ	LÄHTÖTIETO								
	Liikenne-määrä	No-peus	Varau-saste	Matka-aika	Nopeu-den keski-hajonta	Histo-ria-tieto liikenteestä	OD-mat-riisi	Sää, keli	Tietoa liikenne-verkosta
Tilastolliset menetelmät	++	++	+	+		++		+	
Tekoälymenetelmät	++	++	+	++	+				
Simulointi- ja sijoittelumallit	++	++					++		++
Kalman-suodatus	++	++	++						

Taulukossa 1 esitettyjen lähtötietojen lisäksi on myös muita tietoja, joista voisi olla hyötyä lyhyen ajan ennusteiden laatimiseen. Sää- ja kelitiedot eivät ole kovin yleisesti käytettyjä lähtötietoja, mutta etenkin Suomessa niillä on suuri merkitys liikenteen sujuvuuteen. Useat kehitetyt ennustemenetelmät hyödyntävät vain ajantasaisista mittauksista liikenteestä, vaikka tiedot erilaisista yleisötapauksista tai häiriöistä liikenneverkolla voisivat parantaa liikenne-ennustetta. Kuvassa 7 on esitetty eräänlainen "ideaalimalli", joka ottaisi huomioon ajantasaisen mittauksen lisäksi muita liikenteeseen vaikuttavia tekijöitä.



Kuva 7. Periaatekuva ideaalisesta ennustemallista. Ideaalisen ennustemallin tulisi huomioida liikenteestä tehtyjen mittausten lisäksi myös erilaisten häiriöiden ja tapahtumien vaikutukset liikenteen käyttäytymiseen. (Sundberg ym. 2000)

6.3 Ennusteiden arviointi

Eri ennustemenetelmiä on vaikea laittaa paremmuusjärjestykseen. Ennusteen onnistuminen riippuu paljolti kohteesta (kuinka paljon ruuhkaa on, onko se toistuvaa jne.) ja ajankohdasta, jolloin mallia on käytetty. Toiset mallit soveltuvat paremmin toisiin kohteisiin ja mallien vertailu tulisikin suorittaa miettimällä kohteen erityispiirteitä. Ennustevirheet voivat myös vaikuttaa hyvin erilaisilta eri virheen tunnusluvuilla ilmaistuna. Mallit voivat asettua hyvin erilaiseen paremmuusjärjestykseen, jos tarkasteltua tunnuslukua vaihdetaan. Tätä selvitystä varten läpikäytyissä lähteissä on tuloksista kerrottu hyvin eri tavalla. Useimmiten käytettyjä virheen tunnuslukuja ovat MSE (keskineliövirhe), RMSE (keskineliövirheen neliöjuuri), keskivirhe (mean error), virheellisten osuus (error rate), MAPE (keskimääräisen suhteellisen virheen itseisarvo, mean absolut percent error), selitysaste ja korrelaatiokerroin. Määritelmät ja kaavat virheen tunnusluvuista on esitetty liitteessä 2. Useisakaan lähteissä ei ole kerrottu tuloksista kovinkaan tarkasti matemaattisia virheen tunnuslukuja käyttäen.


Tienkäyttäjän ja liikennetiedotuksen kannalta on oleellista, kuinka suuren osan ajasta malli ennustaa oikein (esim. 10 % virhemarginaalilla). Liikennetiedotuksen kannalta erityisen tärkeää on, kuinka suuri osa ruuhka-ajan ennusteista mahtuu virhemarginaalin sisään. Tällaista tietoa ei kuitenkaan ollut saatavilla kuin hyvin pienestä osasta tutkimuksia.

Sallittavan virhemarginaalin asettaminen ei kuitenkaan ole täysin ongelmantonta. Liikennetiedotuksessa lyhyen ajan ennusteista on eniten hyötyä ruuhkatilanteissa, vapaissa oloissa ennustamista ei niinkään tarvita. Mallin tulisi siis olla luotettava erityisesti ruuhkan ennustamisessa. Tulisiko mallille siis asettaa tiukemmat vaatimukset ruuhkaliikenteen kuin normaalin liikenteen ennusteiden tarkkuuden suhteen?

Ruuhkassa ennustaminen on kuitenkin paljon vaikeampaa kuin normaalissa tilanteessa. Mallitekniseltä kannalta katsottuna ruuhka-ajan virhemarginaali voitaisiinkin asettaa vapaata liikennetilannetta suuremmaksi. (Innamaa 2001)

Eri ennustesuureet myös suhtautuvat eri tavalla virhemarginaalin käyttöön. Esimerkiksi matka-aika kasvaa ruuhkan pahentuessa, mikä tarkoittaa sitä, että ruuhkatilanteessa sallittu absoluuttinen poikkeama toteutuneesta matkajasta kasvaa. Nopeus taas alenee ruuhkassa ja nopeusennusteiden sallittu absoluuttinen poikkeama todellisista nopeuksista pienenee. (Innamaa 2001)

On myös pahempi, että malli ennustaa säännöllisesti jotkin tilanteet väärin, kuin että ennusteissa on satunnaisia virheitä, vaikka nämä olisivatkin osittain yli 10 %. Mallin hyvyyden arviointia helpottaa, kun mallin tulokset esitetään kuvaajalla, jossa x-akselilla olisi mitattu (toteutunut) arvo ja y-akselilla ennustettu arvo. Kuvaajan avulla voidaan arvioida minkälaisissa tilanteissa mallilla on erityisiä hankaluuksia. Esimerkki tällaisesta kuvaajasta on kuvassa 8. (Innamaa 2001)



Kuva 8. Mitatun ja ennustetun nopeuden suhtautuminen toisiinsa. Parhaassa tapauksessa mitattu ja ennustettu nopeus asettuvat suoralle $v(\text{ennustettu}) = v(\text{mitattu})$. Esimerkissä nopeusennusteet ovat onnistuneet kohtalaisen hyvin suuremmilla nopeuksilla, mutta pienillä nopeuksilla (ruuhkatilanteessa) malli on aliarvioinut nopeuksia.

Innamaa esitti 1999, että sijoitteluun ja simulointiin perustuvat mallit ovat niin raskaita ja hitaita, etteivät ne sovellu ajantasaisiin sovelluksiin. ARIMA-mallitkaan eivät sovellu tähän tarkoitukseen. Lupaavimmilta Innamaan mukaan vaikuttavat neuroverkot, Kalman-suodatus ja ei-parametrinen lähin naapuri -menetelmä, sekä siihen verrattavissa oleva SOM-neuroverkko. Tässä selvityksessä ei juurikaan tullut esiin seikkoja, jotka olisivat ristiriidassa Innamaan näkemyksen kanssa. Simulointi- ja sijoittelumenetelmillä on vahvuutena verkkonäkökulman ja kuljettajan reitinvalinnan huomioiminen, jotka ovat oleellisia asioita liikennetiedotusta varten tehdyissä lyhyen ajan ennusteissa. Tiedotuspalvelussa ennusteen ei myöskään tarvitse syntyä yhtä nopeasti kuin automaattisissa liikenteenohjausjärjestelmissä. Siksi voidaan olettaa, että simulointi- ja sijoittelumallit ovat käyttökelpoisempia tiedotuspalvelua varten tuotetuissa ennusteissa kuin liikenteenohjausjärjestelmissä.

7. JOHTOPÄÄTÖKSET JA JATKOTOIMENPITEET

Tässä selvityksessä ei löytynyt maailmalla tiedotuspalvelukäytössä olevia järjestelmiä, joihin sisältyisi lyhyen ajan liikenne-ennusteita. Erilaisia menetelmiä ja malleja on kuitenkin kehitetty ja testattu paljon. Tässä selvityksessä läpikäydyistä menetelmistä suurin osa on kehitetty moottoriteliikenteen ennustamiseen ja sopii parhaiten yksittäiselle tieosuudelle. Verkkonäkökulma, joka on tärkeä liikennetilannetiedotuksessa etenkin kaupunkiseuduilla, on mukana harvemmin. Parhaiten verkkonäkökulma tulee esille simulointi- ja sijoittelumalleissa. Nämä mallit ovat kuitenkin hitaita ja työläitä ja vaativat dynaamisen lähtöpaikka-määräpaikka –matriisin lähtötiedoikseen. Liikennetiedotuksessa ja alueellisessa liikenteen hallinnassa tarvittavien ennusteiden aikatahtain on yleensä 5...60 min. Tämä on pidempi kuin liikenteenohjausjärjestelmissä (liikennevalot, väyläohjaus) pääasiassa tarvittava 1...5 min ennustejakso. Mallin nopeus ei siis ole tiedotuksessa ja alueellisessa liikenteen hallinnassa yhtä ratkaisevaa kuin ohjausjärjestelmissä. Rekursiivisuutta eli tiedotuksen vaikutusta liikennetilanteen kehittymiseen ei ollut otettu huomioon kuin harvoissa tutkimuksissa. Suurin osa läpikäydyistä lähteistä keskittyi erilaisiin tilastollisiin malleihin ja neuroverkkojen käyttöön lyhyen ajan liikenne-ennusteissa.

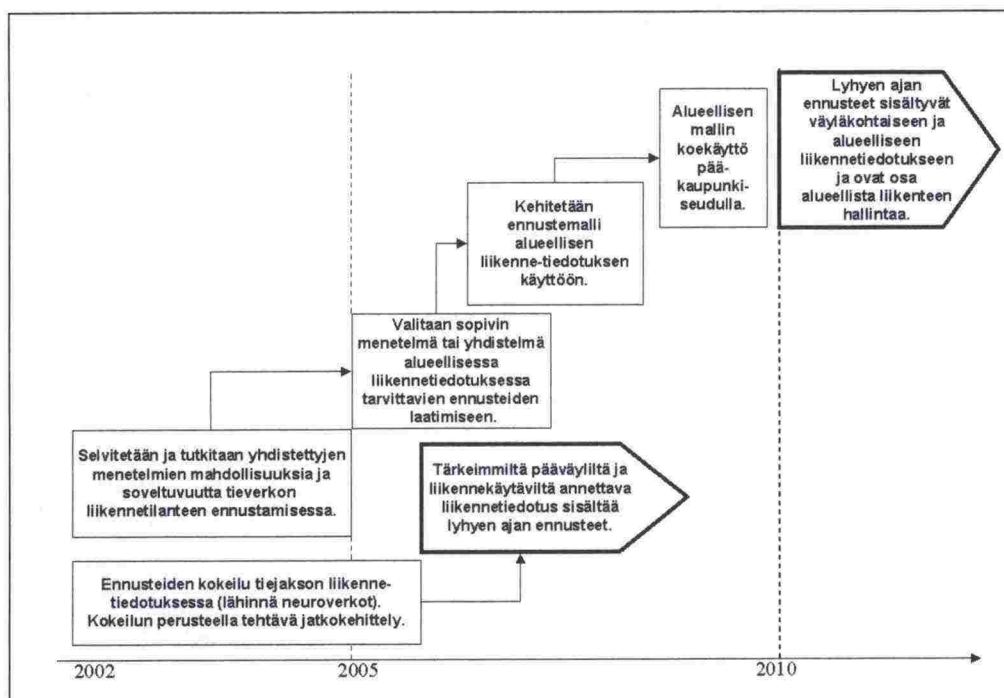
Kaikilla ennustemenetelmillä on hyvät ja huonot puolensa. Selvityksessä löytyi myös malleja, joissa on yhdistetty useita menetelmätyyppejä, jotta eri menetelmien hyvät puolet voitaisiin hyödyntää. Menetelmien yhdistely vaikuttaa lupaavalta, koska mikään yksittäinen menetelmätyyppi ei ole noussut selkeästi toisia paremmaksi. Esimerkiksi neuroverkkoja voitaisiin yhdistellä malliin, joka tekisi dynaamisen lähtöpaikka-määräpaikkamatriisin ja sijoittelisi liikenteen verkolle. Myös rekursiivisuus eli tienkäyttäjien reagoiminen liikennetiedotukseen tulisi ottaa ennustemallissa huomioon.

Lyhyen ajan ennusteista on tiedotuspalvelussa eniten hyötyä liikenteen ollessa ruuhkautunutta. Tiedotuksen näkökulmasta ei ole syytä hyväksyä ennusteissa suurempaa virhemarginaalia ruuhka-aikana kuin muulloin. Ennusteiden tarkkuus on tiedotuspalvelussa kenties vielä tärkeämpää kuin liikenteenohjausjärjestelmissä. Tiedotuspalvelussa liikenteen ennustettu sujuvuus kerrotaan tienkäyttäjälle suoraan, ohjausjärjestelmissä tienkäyttäjää koee ennusteen onnistumisen välillisesti ohjauksen toimintana. Tavoitteena voisikin olla 5 %:n virhemarginaali.

Lyhyen ajan ennustemenetelmät tarvitsevat useimmiten ajantasaista mittaustietoa liikennemäärästä, liikennevirran keskinopeudesta ja ilmaisimen varausasteesta. Nämä lähtötiedot sisältyvät Liikenteen seurannan valtakunnallisessa esiselvityksessä määriteltuihin määrämuotoisiin liikennetietoihin, joita tarvitaan liikenteen hallinnan peruspalveluiden tuottamiseen (Tiehallinto 2001a).

Tämän selvityksen perusteella ei voida sulkea pois mitään menetelmää vaan pikemminkin mallien kehittämisessä tulisi pyrkiä hyödyntämään eri menetelmien hyviä puolia. Menetelmien kehittämisessä ja kokeiluissa tulisi jatkossa painottaa enemmän liikenteen tiedotuksessa ja alueellisessa ohjauksessa vaadittavaa verkkonäkökulmaa.

Kuvassa 9 esitetään ehdotus jatkotoimenpiteistä ja kehityspolusta sekä niiden aikataulusta, kun tavoitteeksi on asetettu, että viimeistään vuonna 2010 lyhyen ajan ennusteet sisältyisivät liikennetiedotukseen ja alueelliseen liikenteen hallintaan. Välitavoitteena on, että ennusteet sisältyisivät tärkeimmiltä pääväylyiltä ja liikennekäytäviltä annettavaan liikennetiedotukseen jo vuonna 2005...2006. Alueellista liikenteen hallintaa (sisältää häiriöiden hallinnan) varten tarvitaan ennusteita alueen ja tieverkon liikennetilanteen kehittymisestä. Aluksi tulisi selvittää eri ennustemenetelmien yhdistelyn mahdollisuuksia ja soveltuvuutta nimenomaan alueelliseen liikenteen hallintaan ja ennustamiseen. Selvitysten perusteella valitaan käyttökelpoisin menetelmä tai menetelmien yhdistelmä ja tämän pohjalta kehitetään malli tai mallit alueellista liikenteen hallintaa ja tiedotusta varten. Ennen ennusteiden käyttöönottoa mallit on validoitava ja testattava.



Kuva 9. Ehdotus jatkotoimenpiteistä ja niiden alustava aikataulu.

LÄHDELUETTELO

Hintikka J, Göös J, Neuroverkot, VTT Elektroniikka, Älykkäät järjestelmät (viitattu 10.8.2001) <http://www.vtt.fi/ele/tutkimus/soh/aly/neuroverkot.htm>

Hintikka J, Göös J, Sumea mallinnus, VTT Elektroniikka, Älykkäät järjestelmät (viitattu 10.8.2001) http://www.vtt.fi/ele/tutkimus/soh/aly/sumea_mallinnus.htm

Holma M (1991). Kalman-suodatuksen periaatteet ja käyttö liikenneteknisissä mittauksissa ja liikenteen ohjauksessa. Matematiikan erikoistyö, Teknillinen korkeakoulu, Espoo. 15+3 s.

Honkela T, Neuroverkot: johdatus moderniin tekoälyyn, TKK Neuroverkkojen tutkimusyksikkö (viitattu 10.8.2001) <http://www.cis.hut.fi/~tho/stes/step96/honkela2/>

Innamaa S (1999). Automaattiset liikenteenohjaus- ja liikenneinformaatiojärjestelmät. Tielaitoksen selvityksiä 28/1999, Tielaitos, Helsinki. 136 s.

Innamaa S, Pursula M (2000). Liikennemäärän ja nopeuden lyhyen aikavälin ennustaminen. Tielaitoksen selvityksiä 54/2000, Tielaitos, Helsinki. 102+3 s.

Innamaa S (2001). Tutkija, DI Satu Innamaan kanssa käyty sähköpostikeskustelu 23.7. – 13.8.2001

Juutilainen T, Käytännön kokemuksia neuraalilaskennasta prosessinohjauksessa, Control Express Finland Oy (viitattu 10.8.2001) <http://www.tacnet.sci.fi/Opetus/autom95/sm/71/cdluento.htm>

KAREN 2000. European ITS Framework Architecture. Issue 1.0 (CD). European Communities 2000.

Karvonen T, Kettunen J, Vakkilainen P (1982). Kalman suodattimen käyttö hydrologisten ja ekologisten mallien tilan identifioinnissa ja parametriestimoinnissa. Monistesarja 1982:1, Teknillinen korkeakoulu, Vesitalouden laboratorio, Espoo. 45 s.

Kiljunen M, Summala H (1996). Ruuhkaisuuden kokeminen ja liikennetilantiedottaminen. Tienkäyttäjätutkimus kaksikaistaisilla teillä. Tielaitoksen selvityksiä 25/1996, Tielaitos, Helsinki. 77+5 s.

Lind G (2000). Strategies for Route Choice Information – Factors Influencing the Magnitude of User Benefits. Konferenssi-cd 7th World Congress on Intelligent Transport Systems, 6-9 November 2000, Turin, Italy. 8 s.

Milne D (2001). Tutkija Dave Milnen sähköpostihaastattelu 31.8.2001.

Mäkelä K, Niittymäki J, Kosonen I, Nevala R (2001). Fits Liikennetelematiikan rakenteiden ja palvelujen tutkimus- ja kehittämisohjelma 2001 – 2004, Älykäs liikenteenohjaus, Sumeaan logiikkaan ja simulointiin perustuvan liikennevalo-ohjauksen tuotteistaminen, Tuotteistamissuunnitelma 16.8.2001

(viitattu 19.10.2001) <http://www.hel.fi/liikenteenohjaus/fits/sumeantuottaistaminen.htm>

Pesonen E, Sumea logiikka, Kuopion yliopisto, Tietojenkäsittelytieteen ja sovelletun matematiikan laitos (viitattu 10.8.2001) <http://www.cs.uku.fi/~epesonen/opetus/aly/sumea.html>

Schultz R, Werwatz A, General Kalman Filtering (viitattu 10.8.2001) <http://www.xplore-stat.de/tutorials/gkalframe1.html>

Sundberg J, Ekdahl T, Hanson S (2000). Korttidsprognoser för parkeringsefterfrågan. KFB projekt Dnr 1997-0646. 45 s.

Tekes, Sumean logiikan mahdollisuudet (viitattu 10.8.2001) <http://www.tekes.fi/julkaisut/sumea/index.html>

Tiehallinto (2001a). Liikenteen seurannan valtakunnallinen esiselvitys. Tiehallinnon selvityksiä 19/2001, Tiehallinto, Helsinki. 55 s.

Tiehallinto (2001b). Tiehallinnon liikenteen hallinnan toimintalinjat -taustaraaportti. Tiehallinto, Helsinki. 69 s.

Nimi	MLP -neuroverkkojen soveltaminen liikennetilanteen ennustamiseen
Tyyppi	Mallin kehittäminen
Toteutusajankohta	Touko-kesäkuu 1999
Kohde	Länsiväylä, Helsinki-Espoo, Suomi
Alueen koko	3 km moottoritiejakso
Tilaaaja	Tielaitos, Liikenne- ja viestintäministeriö
Yhteyshenkilö	satu.innamaa@hut.fi
Tavoite	Selvittää, millainen neuroverkko soveltuisi parhaiten lyhyen aikavälin liikennetilanteiden ennustamiseen.
Ennustemalli	Eteenpäin syöttävä monikerrosperserptronineuroverkko (multi-layer perceptron network, MLP).
Perustoiminta	Parhaita tuloksia antaneessa mallissa on kaksi neuroverkkoa, joista toinen ennustaa liikennemääriä ja toinen nopeuksia.
Input	
Lähtötiedot	Nopeus- ja liikennemäärähavainnot 15 viimeiseltä minuutilta 5 minuutin jaksoissa normeerattuina ja pääkomponenttianalyysin avulla käsiteltyinä tai skaalattui- na. Joissain malleissa myös ajankohtatiedot tai nopeuden keskihajonta.
Tietolähteet	Induktioilmaisimet. Ilmaisimien sijainnille on olemassa optimaaliset sijoituskohdat, jotka riippuvat paikallisista olosuhteista ja ennustejakson pituudesta.
Muuta	Syötetietona ei kannata antaa liikaa dataa, jos vähemmällä päästään hyviin tuloksiin. Sää- ja kelityyppi kannattaa lisätä malliin yhdeksi syöteparametriksi. Kellonajan ja päivän tai nopeuskeskihajontatietojen antaminen ei parantanut tuloksia.
Output	Liikennemäärä- ja nopeusennuste seuraaville 15 minuutille 5 minuutin jaksoissa
Rajoitukset ja käyttöympäristö	Sopii yksittäiselle tielle, verkkonäkökulmaan huonommin.
Tulokset	Liikennemääräennusteet onnistuivat paremmin kuin nopeusennusteet. Nopeusennusteissa oli systemaattista virhettä, malli yliarvioi alhaisia nopeuksia. Liikennemääräennusteista 64 % ja nopeusennusteista 99 % mahtui 10 %:n virhemarginaaliin. Tulokset eivät huonontuneet ennustejakson pituuden kasvaessa.
Ongelmat	Induktioilmaisimista saadun datan kanssa oli ongelmia. Ilmaisista virheellisiä oli 38-48% mm. sen takia, että ajoneuvon liike oli epätasainen tai poikkeava. Käytetyn datajoukon pienyydestä johtuen mallin oli vaikea ennustaa ruuhkanopeuksia. Tarkasteltu tieosuus olisi myös saanut olla pidempi.
Muuta	Vertailututkimus kaksikaistaisella tiellä vt 3:lla Valkeakoskella touko-lokakuussa 1999. Mallin syötetiedot ennustehetkeä edeltävän puolen tunnin ajalta (viiden minuutin jaksojen liikennemäärä, keskinopeus ja keskimääräiset jonoprosentit). Havaittiin, että vastakkaisen suunnan liikennetietojen vaikutus tuloksiin oli pieni. Jonoprosenttien ennustaminen onnistui suhteellisen hyvin. Havaittiin, että Länsiväylälle kehitettyä mallia voidaan suurelta osin soveltaa myös kaksikaistaiselle tielle.
Lähteet	Innamaa S (2000). Short-Term Prediction of Traffic Situation Using MLP-Neural Networks. 7th World Congress on Intelligent Transport Systems. Turin, Italy, 6 - 9 Nov. 2000. 8 p. Innamaa S, Pursula M (2000). Liikennemäärän ja nopeuden lyhyen aikavälin ennustaminen. Tielaitoksen selvityksiä 54/2000, Tielaitos, Helsinki. 102+3 s.

Nimi	Matka-ajan ennustaminen epälineaarisen aikasarjamallin avulla
Tyyppi	Mallin kehittäminen
Kohde	
Alueen koko	Orlando, Florida, USA
Toteutusajankohta	18 km moottoritiejakso
Tilaaaja	
Yhteyshenkilö	Matthew P. D'Angelo, Haitham M. Al-Deek, Morgan C. Wang
Tavoite	Tiejakson matka-ajan ennustaminen liikenneinformaatiota varten.
Ennustemalli	Epälineaarinen aikasarjamalli. Vertailussa mukana yhden muuttujan (nopeus) ja usean muuttujan (nopeus, liikennemäärä, varausaste) malli.
Perustoiminta	Ennustetaan seuraava arvo v_{n+1} kun tiedetään aikasarja v_1, \dots, v_n .
Input	
Lähtötiedot	Havainnot nopeudesta, liikennemäärästä ja ilmaisimen varausasteesta 30 s välein, jotka yhdistetään 5 minuutin keskiarvoiksi. Aikasarja kerättiin 2,5 h ajalta (30 havaintoa). Mallia käytettiin aamun ruuhkatunteina (klo 6:00-10:00)
Tietolähteet	Induktioilmaisimet 800 m välein
Muuta	30 s välein saatavien nopeushavaintojen yhdistäminen 5 min keskiarvoksi tuottaa harhaa. Havaintojen yhdistämiseen käytettiin suodattamista. Havaittiin, että suodattaminen tasajakaumaa käyttäen antoi parhaat tulokset.
Output	Nopeuden ja siitä lasketun tiejakson matka-ajan ennuste 5 min välein.
Rajoitukset ja käyttöympäristö	
Tulokset	Yhden muuttujan malli tuotti parempia tuloksia kuin usean muuttujan malli. Tuloksista 98% oli 10% virhemarginaalin sisällä. Keskimääräinen matka-ajan ennusteen virhe oli 1,3%.
Ongelmat	Ongelmia oli liikennetilanteen muuttuessa. Ruuhkan syntyessä ja purkautuessa ennusteissa oli enemmän virhettä, kuin vakaassa tilanteessa (eli ruuhkattomana ja ruuhkan aikana). Kaaosteoriaa tai tekoälyä voitaisiin ehkä soveltaa muuttuvien tilanteiden ennustamisessa.
Muuta	Epälineaarinen aikasarjamalli voi antaa epärealistisen alhaisia nopeusennusteita. Kynnysarvoksi asetettiin testien perusteella 16 km/h, jota pienemmät arvot korvattiin viereisten ilmaisinvälien ennusteiden keskiarvoilla.
Lähteet	D' Angelo M, Al-Deek H, Wang M (1999). Travel-Time Prediction for Freeway Corridors. Transportation Research Record, No. 1073. s. 184-191.

Nimi	Matka-aikojen ennustaminen modulaarisen neuroverkon avulla
Tyyppi	Mallin kehittäminen
Toteutusajankohta	1996 (231 arkipäivää)
Kohde	US-290 (6-kaistainen moottoritie), Houston, Texas, USA
Alueen koko	27,6 km tiejakso
Tilaaja	
Yhteyshenkilö	Dongjoo Park, Laurence R. Rilett
Tavoite	Linkkien matka-aikojen ennustaminen liikenneinformaatiota varten
Ennustemalli	Modulaarinen neuroverkko
Perustoiminta	Tilastoidut matka-ajat jaettiin luokkiin valvomatonta ryhmittelytekniikkaa käyttäen. Ryhmittelytekniikoina käytettiin itseorganisoivaa karttaa (self-organizing map, SOM) ja sumeaa logiikkaa (fuzzy c-means clustering technique). Jokaiselle luokalle luodaan oma neuroverkko matka-aikojen ennustamista varten.
Input	
Lähtötiedot	Linkkien matka-ajat aggregoituna 5 min matka-aikahavainnoiksi. Mallia käytettiin aamun ruuhkatunteina (klo 6:00-10:00)
Tietolähteet	Automaattinen ajoneuvon tunnistusjärjestelmä, 7 tunnistuspistettä
Muuta	
Output	Linkkien matka-ajat seuraaville 5-25 minuutille
Rajoitukset ja käyttöympäristö	Mallia tehtäessä on huomioitava ryhmien määrä ja niiden ominaisuuksien erotelu sekä ryhmittelyyn käytettävät parametrit ja niiden painokertoimet. Ennustejakson pituuden kasvaessa ennustevirhe kasvaa ja jossain vaiheessa (1-2 h ->) historiadataa käyttävä malli voi antaa parempia tuloksia.
Tulokset	Sumeaa logiikkaa käyttävä ryhmittelytekniikka antoi hieman parempia tuloksia kuin itseorganisoivaa karttaa käyttävä. Ennustevirhe sumeaa logiikkaa käyttäen oli 8,1-15,7 % ja SOMia käyttäen 8,2-16,4 %. Virhe kasvoi ennustejakson pituuden kasvaessa. Parhaisiin tuloksiin päästiin luokkien eli neuroverkkojen määrän ollessa 10.
Ongelmat	Malli vaatii vielä tutkimista ja kehittämistä mm. parhaan havaintojakson pituuden sekä sopivan neuroverkkomallin löytämiseksi.
Muuta	
Lähteet	Park D, Rilett L (1998). Forecasting Multiple-Period Freeway Link Travel Times Using Modular Neural Networks. Transportation Research Record, No. 0743. s. 163-170.

Nimi	Matka-ajan ennustaminen MLP-neuroverkolla
Tyyppi	Mallin kehittäminen
Kohde	vt 4, Lahti-Heinola, Suomi
Alueen koko	28 km tiejakso
Toteutusajankohta	Kesä-elokuu 2000
Tilaaja	Tiehallinto, Liikenne- ja viestintäministeriö
Yhteyshenkilö	satu.innamaa@hut.fi
Tavoite	Selvittää, minkälaisilla syötteillä saadaan aikaiseksi paras matka-aikaennuste ja miten järjestelmän rakenne vaikuttaa ennusteeseen.
Ennustemalli	Eteenpäin syöttävä monikerroserseptroniverkko (multi-layer perceptron network, MLP)
Perustoiminta	Kullekin osalinkille ja osalinkkiyhdistelmälle oma neuroverkko.
Input	
Lähtötiedot	Korrelaation perusteella valittuja eri osalinkkien ja osalinkkiyhdistelmien erilaisia keski- ja mediaanimatka-aikoja sekä matka-ajan keskihajontoja sekä LAM-pisteistä liikennemääriä, keskinopeuksia ja nopeuskeskihajontoja
Tietolähteet	Matka-aikoja mittaava järjestelmä (automaattinen ajoneuvon tunnistus) ja induktioilmaisimet.
Muuta	Lisäkamerapisteet parantavat tulosta enemmän kuin lisä-LAM-pisteet.
Output	Matka-aikaennuste kullekin osalinkille ja osalinkkiyhdistelmälle seuraavan minuutin aikana saapuville ajoneuvoille
Rajoitukset ja käyttöympäristö	Sopii yksittäiselle tielle sekä verkolle. Opetusjoukon tulee olla riittävän laaja ja ruuhkatilanteiden ennakoimiseksi verkkoa täytyy opettaa riittävän laajalla ruuhka-ajan aineistolla.
Tulokset	Paras malli ennusti oikein yli 90 % ajasta ruuhkaliikenteessä. Mallien hyvyys vaihteli suunnan ja sen mukaan, oliko linkki jaettu osalinkkeihin vai ei (oikein ennustetut 60%-90,3% ruuhkaliikenteessä). Malli yliarvioi matka-aikoja hieman.
Ongelmat	Aineistossa oli vähän ruuhkaisia päiviä. Mitattujen matka-aikojen osuus oli pieni, koska kameroita vain yhdellä kaistalla / suunta.
Muuta	Aineistoa kerätään lisää kesän 2001 aikana ja malleja pyritään parantamaan uuden datan avulla.
Lähteet	Innamaa S (2001, accepted to be published). Short-Term Prediction of Highway Travel Time Using MLP-Neural Networks. 8th World Congress on Intelligent Transport Systems. Sydney, Australia, 30 Sept. - 4 Oct. 2001. 12 p.

Nimi	Liikennetilanteen ennustaminen tilasto- tietojen ja nykytilan mittausten avulla
Tyyppi	Mallin kehittäminen
Kohde	Moottoritieverkko lähellä Amsterdamia, Hollanti
Alueen koko	
Toteutusajankohta	
Tilaaja	
Yhteyshenkilö	Rik van Grol, Domenico Inaudi, Eric Kroes
Tavoite	Matka-ajan ennustaminen, vaikeasti ennustettavien tilanteiden tunnistaminen (ennusteen tarkkuus voidaan määrittää ja kertoa tienkäyttäjille).
Ennustemalli	Tilastollinen kehitys talletettuna tietokantaan
Perustoiminta	Liikennetiedot on tallennettu aikasarjoina viikonpäivän mukaan jaotellen. Aika-sarjaa päivitetään antamalla uusille havainnoille suurempi painoarvo. Ennus-teita voidaan korjata ilmaisimilta saadun reaaliaikaisen tiedon avulla.
Input	
<i>Lähtötiedot</i>	Liikennemäärät ja nopeudet viikonpäivän mukaan jaoteltuna
<i>Tietolähteet</i>	
<i>Muuta</i>	Säätyyppiä voitaisiin myös käyttää luokitteluun viikonpäivän lisäksi.
Output	Liikennemäärä ja nopeus
Rajoitukset ja käyttöympäristö	
Tulokset	Reaaliaikainen mittaustieto liikenteestä paransi ennustuksia vai hieman. Reaa-liaikaisesta tiedosta ei ollut hyötyä puolta tuntia pidemmälle meneville ennus-teille.
Ongelmat	Ei kykene ennustamaan yllättäviä ruuhkatilanteita.
Muuta	Liikennetilanteiden ennustaminen on vaikeaa mutta toisissa tilanteissa voidaan ennustaa tarkemmin kuin toisissa. On tärkeää tietää ennusteen tarkkuus ja kertoa tienkäyttäjille myös matka-aikojen hajonnasta kussakin tilanteessa.
Lähteet	Grol R van, Inaudi D, Kroes E (2000). On-Line Traffic Condition Forecasting Using On-Line Measurements and a Historical Database. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy. 10 s.

Nimi	Reaaliaikaisen ja ennustetun liikennetiedon jakaminen tienkäyttäjille
Tyyppi	
Kohde	Melbourne, Australia
Alueen koko	
Toteutusajankohta	Kokeilu alkoi lokakuussa 1999, autoilijoita mukana yli 70
Tilaaja	
Yhteyshenkilö	Charles A Karl, Roslyn S Trayford
Tavoite	Tuottaa ja jakaa autoilijoille informaatiota liikenteen sujuvuudesta ja sitä kautta välttää ruuhkien syntymistä. Tavoitteena myös tutkia milloin ja millaista informaatiota autoilijat haluavat ja miten sitä voidaan jakaa nykyistä tekniikkaa käyttäen.
Ennustemalli	Monimuuttujaregressiomalli, monimuuttuja aikasarja-analyysi, neuroverkkomalli (spectral analysis), piece-wise daily templates
Perustoiminta	Autoilijoista on tehty tietokanta, joka sisältää jokaisen autoilijan profiilin (vakituisen matkan lähtö- ja määräpaikka, lähtöaika, moottiritien liittymis- ja poistumisramppi ym.). Autoilijoille lähetetään vähän ennen lähtöä tekstiviesti, joka kertoo ennustetun matka-ajan, tiedot häiriöistä ja säästä. Matkan aikana voidaan lähettää informaatiota esim. onnettomuuksista.
Input	
Lähtötiedot	Nykyinen matka-aika, sää, onnettomuudet, ennustemallia varten tilastotietoa liikenteestä
Tietolähteet	Induktiosilmukat, liikennevalot, videokamerat, GPS/GSM -paikannus, manuaaliseuranta, sää, media
Muuta	
Output	Ennustettu matka-aika
Rajoitukset ja käyttöympäristö	Lähtötietoa tulee kerätä koko kaupungin alueelta, ei vain moottoriteiltä. Autoilijoille tulee jakaa sekä reaali-aikaista että ennustetietoa ja tiedonjakoon tulee olla monia eri kanavia.
Tulokset	Lyhyillä matkoilla ennustevirhe voi olla suuri, mutta sillä ei ole käytännön kannalta merkitystä. Pidemmällä matkoilla (yli 30 min) yllättävien tapahtumien vaikutus tasoittuu.
Ongelmat	
Muuta	
Lähteet	Karl Jr C A, Trayford R S (2000). Delivery of Real-Time and Predictive Travel Time Information: Experiences from Melbourne Trial. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy. 10 s.

Nimi	Moottoritien liikenteen ennustaminen simulointi- ja sijoittelumallilla
Tyyppi	Mallin kehittäminen
Kohde	Moottoritiejakso välillä Vienne – Montpellier/Lancon, Ranska
Alueen koko	310 km tieverkko, 29 eritasoliittymää
Toteutusajankohta	Kesä 1995
Tilaaja	ASFA (Association des Societes Francaises d'Autoroutes)
Yhteyshenkilö	Jean-Marc Morin, Bernard Baradel, Joel Bomier
Tavoite	Liikennetilanteiden ennustaminen
Ennustemalli	Malliin kuuluu OD-matriisit ennustava MITHRA 2 ja liikennevirran makroskoopinen simulointimalli SIMRES, jotka saavat lähtötietoa automaattisesta liikenteenmittausjärjestelmästä (MISTRAL).
Perustoiminta	MITHRA ennustaa tulevan OD-matriisin vertailemalla nykyhetken liikennemittauksia tilastoituihin ja luokiteltuihin OD-matriiseihin. SIMRES-mallissa tieverkko on mallinnettu jakamalla se 2 km pituisiin osiin, joille on määritetty nopeus-liikennetiheys –suhde liikennemittausten perusteella.
Input	
Lähtötiedot	MITHRA: usean vuoden tilastoidut OD-matriisit, tämän hetkinen liikennemäärä. SIMRES: ajantasainen mittaustieto liikenteestä (liikennemäärä, nopeus, varausaste). Tiedot 6 min välein.
Tietolähteet	49 mittauspistettä, tiedot 20 km välein
Muuta	
Output	Varausasteeseen ja nopeuteen perustuva liikennetilanneluokka. Rinnakkain esitetään nykytilanne ja ennustettu liikennetilanne (2 tunnin päästä).
Rajoitukset ja käyttöympäristö	
Tulokset	OD-matriisin suhteellinen neliökeskivirhe (MRQE = mean relative quadratic error) tunnin ennusteille 25 % ja kahden tunnin ennusteille 34 %. Liikennemäärän tämän hetken estimaatin MRQE 16-18 % ja kahden tunnin ennusteen MRQE 24-28 %.
Ongelmat	
Muuta	Lisää käyttötestejä kesällä 1996. Malliin tarkoitus lisätä mahdollisuus simuloida liikenteen ohjaustoimien vaikutuksia.
Lähteet	Morin J-M, Baradel B, Bomier J (1996). On-Line Short Term Simulation and Forecast of Motorway Traffic Patterns: Field Results Obtained on ASF Network in France. 3th World Congress on Intelligent Transport Systems, 14-18 October 1996, Orlando, USA. 9 s.

VIRHETERMIT

MSE = mean squared error

MSE eli keskineliövirhe on mittaluku, jolla kuvataan aineiston perusteella es-
timoitavalle parametrille muodostetun estimaatin tarkkuutta. MSE lasketaan
parametrin estimaatin ja todellisen arvon välisen eron neliön odotusarvona.
Mikäli estimoitava parametri on θ ja mikäli sille otoksen perusteella laskettu
estimaatti $\hat{\theta}$, on estimaattiin liittyvä keskineliövirhe

$$MSE = E(\hat{\theta} - \theta)^2$$

$$MSE = \frac{1}{n} \sum_i (y_i - \hat{y}_i)^2$$

RMSE = root mean squared error

RMSE on yksinkertaisesti MSE:n eli keskineliövirheen neliöjuuri.

$$RMSE = \sqrt{\frac{1}{n} \sum_i (y_i - \hat{y}_i)^2}$$

Korrelaatiokerroin

Korrelaatiokerroin mittaa lineaaristen riippuvuuksien voimakkuutta. Korrelaa-
tiokertoimen arvo voi vaihdella välillä $-1 \dots 1$. Korrelaatiokertoimen positiivi-
nen arvo tarkoittaa, että muuttujien välillä on positiivinen riippuvuus. Vastaa-
vasti negatiivinen korrelaatiokerroin viittaa negatiiviseen riippuvuuteen.
<http://noppa5.pc.helsinki.fi/uudet/da1htm/sanasto.html>

Selitysaste R^2

Selitysaste R^2 kertoo, kuinka suuren osan selittävä muuttuja pystyy selittä-
mään selitettävän muuttujan vaihtelusta. Selitysaste vaihtelee välillä $0 \dots 1$.
Selitysaste on sitä lähempänä ykköstä, mitä paremmin selitettävän muuttu-
jan vaihtelu saadaan selitettyä. Yhden muuttujan regressiomallin selitysaste
on korrelaatiokertoimen neliö. (www.valt.helsinki.fi/atk/stat/regressio.htm)

	ENN. MENE- TELMÄ	TEKIJÄ(T)	LÄHDE	MAA	VOOSI	TAVOITE	TOIMINTA	INPUT	OUTPUT	MALLIN RAJOITUKSET	KÄYTÖSSÄ?	TULOKSET
1.	Sij + sim	Casimir J. de Rham, Rainer Lange	Short Term Forecast and Evaluation for Intelligent VMS Setting. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy. 7 s.	Saksa	2000	Liikenteen tasapainoinen sijoittelu verkolla muuttuvien opasteiden avulla.	Malli luo dynaamisen OD-matriisin ilmaisten avulla saatavien liikennetietojen perusteella, tekee simuloinnin erilaisilla muuttuvilla opasteilla ja valitsee parhaat opasteet kuormitusasteen minimin perusteella.	Tiedot kevyiden (lyhyiden) ja raskaiden (pitkien) ajoneuvojen määrästä ja nopeudesta 300 induktiosilmukalta 5 min välein	Tiedot OD-matriisin kalibroinnista, muuttuvien opasteiden tiedot 15 min välein		Testattu kahdella rinnakkaisella moottoritillä Darmstadtin ja Heidelbergin välillä	Kuormitusaste putosi ruukassa 10% ja ruuhkattomana aikana kasvoi saman verran
2.	Tekoäly	Satu Innamaa	Short-Term Prediction of Traffic Situation Using MLP-Neural Networks. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy. 8 s.	Suomi	2000	Eri tekijöiden vaikutus lyhyen ajan ennusteisiin. Parhaan neuroverkon ja inputin löytäminen	Omat mallit keskinopeuden ja liikennemäärän ennustamiseen	5 minuutin havainnot nopeudesta ja liikennemäärästä	Nopeus- ja liikennemääräennuste seuraavalle 15 minuutille	Sopii yksittäiselle tielle, verkolle huonommin.	Testattu Länsiväylällä (myös vt 3:lla Valkeakoskella)	Nopeusennusteissa systemaattista virhettä, liikennemääräennusteet onnistuivat paremmin. MSE nopeudelle 5-7, MSE liikennemäärälle 36000-66000. Liikennemääräennusteista 64 % ja nopeusennusteista 99 % mahtuu 10 %-n virhemarginaalin sisään.
3.		B. S. Kerner, M. Aleksic, H. Rahbom, A. Haug	Methods for the Tracing and Prediction of Traffic Flow Patterns in the Congested Regime. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy. 8 s.	Saksa	2000	Liikennevirran ennustaminen. Mallit, joita ei tarvitse aina validoida olosuhteiden muuttuessa	Liikennetilanne jaettu kolmeen luokkaan: vapaa, jonoutunut ja ruuhkautunut. Ruuhkat ja muut liikennetilanteet jäljitellään automaattisesti ja ruuhkan etenemisnopeutta käytetään liikennetilanteen ennustamiseen.	Liikennemäärä ja nopeus	Ei liikennetilanteet (traffic objects) (vapaa, jonoutunut, ruuhkautunut) ja niiden eteneminen tielverkolle		Testattu Hessenissä moottoritillä	
4.	Tilasto, tekoäly	Giovanni Huisken, Martin van Maarseveen	Congestion Prediction on Motorways: a Comparative Analysis. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy. 7 s.	Hollanti	2000	Esitellä ja vertailla eri menetelmiä lyhyen ajan ennusteiden laatimiseen	lineaarinen regressio, aikasarja-analyysi, monikerroksen perseptoriverkko, radial basis function networks, sumea logiikka, itseorganisoiuva kartta	Liikennemäärä, nopeus, nopeuden keskijointa ja varausaste induktiosilmukoilta	Onko ruuhkaa odotettavissa vai ei		Testidat kerätty Hollannissa neljän viikon ajalta	ARIMA, MLP, RBF ja sumea logiikka antoivat hyvin samankaltaisia tuloksia. MLR epäonnistui ja SOM jätettiin pois suuren virheellisuuden takia.
5.	Tilasto	Charles A. Karl Jr, Roslyn S. Trayford	Delivery of Real-Time and Predictive Travel Time Information: Experiences from a Melbourne Trial. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy. 8 s.	Australia	2000	Reaaliaikaisen ja ennustetun tiedon jakaminen liikenteen käyttäjille tekstiviesteinä, kokemukset	Autoilijoille lähetetään ennen matkaa viesti, jossa kerrotaan ennustettu matka-aika. Matkan aikana voidaan myös lähettää informaatiota esim. onnettomuuksista. Matemaattinen ennustemalli, joka käyttää historiadatua sekä ajantasaisista liikennetietoa viivytysten ja matka-aikojen ennustamiseen.	Liikennetietoa induktiosilmukoilta, liikennevaloista, videokameroilta, GPS/GSM-paikannus, säätietoja	Matka-ajan ennuste	Lähtötietoa tulee kerätä koko kaupungin alueelta, ei vain moottoritteilla. Autoilijoille tulee jakaa sekä reaaliaikaista että ennustetietoa ja tiedonjakoon tulee olla monia eri kanavia.	Testejä Melbourneissa (70 autoilijaa)	
6.		Gunnar Lind	Strategies for Route Choice Information - Factors Influencing the Magnitude of User Benefits. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy. 8 s.	Ruotsi	2000	Miten eri tekijät reitinvalintaa koskevassa informaatioissa vaikuttavat käyttäjien toimintaan, mitkä tekijät vaikuttavat reitinvalintaan						Reitinvalintaan vaikuttavat matka-ajan lisäksi mm. tieluokka, luotettava saapumisaika ja omat mielipyykset. Informaatio on sitä hyödyllisempää, mitä aiemmin se annetaan. Reitinvalintaa kannattaa suosittelua vasta tietyn hyödyn (kynnysarvo) jälkeen

ENN. MENE-TELMA	TEKIJÄ(T)	LÄHDE	MAA	VUOSI	TAVOITE	TOIMINTA	INPUT	OUTPUT	MALLIN RAJOITUKSET	KÄYTÖSSÄ?	TULOKSET
7. Sij + sim	G. Jarjees, C. R. Drane	Prediction of Vehicle Travel Times Using Ancillary Information Sources. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy. 9 s.	Australia	2000	Matka-aikojen ennustaminen	Dynaaminen simulointimalli. Ajoneuvot jaettu luokkiin saapumisajan mukaan (suhteessa liikennevalojen kiertoon)	Jokaisen linkin keskimääräinen, minimi- ja maksiminopeus, ajoneuvojen sijainti ja liikennevalojen kiert	Ajoneuvon lähtöaika valo-ohjatusta risteyksestä. Näistä muodostuu N:n risteysen jälkeen 2 ^N eri ajo-aikavaihtoehtoa eri todennäköisyyksillä.	Voidaan käyttää vain valo-ohjatuilla tieosuuksilla	Testattu simuloituilla busseilla TRITRAM-simulointiohjelmalla	Ajoneuvon ennustettu lähtöaika risteyksestä poikkesi alle 10 sekunnilla oikeasta ajasta n. 90 % ennusteista. Jos ajoneuvo myöhästyy vihreästä, ennustevirhe kasvaa radikaalisti (systemaattinen virhe).
8. Tilasto, tekoäly	S. Rosswog, P. Wagner	A Comparative Study of Traffic State Predictions: Affited Template Technique (FTT) versus Neural Networks. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy. 5 s.	Saksa	2000	FTT-menetelmän ja monikerroserseptronin neuroverkkojen vertailu	FTT-menetelmässä ennustetaan tilastotiedon pohjalta parantaen ennustetta tämän hetken liikennetiedolla.	Tilastotietoa liikenteestä	Liikennemäärä tietyissä laskentapisteissä		Testit Kölnissä touko-lokakuussa 1999	FTT-menetelmällä keskivirhe 12% 15 min ennusteilla ja 13% tunnin ennusteilla. Neuroverkolla keskivirhe 9% 15 min ennusteilla.
9. Tilasto	Tomoaki Okada, Norihiro Izumi	Providing Information of Predicted Travel Time for Use of Travel Planning Stage. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy. 7 s.	Japani	2000	Matka-aikojen ennustaminen liikenneinformaatiota varten	Ennusteet perustuvat liikenteen kausi-, viikko- ja vrk-vaihteluun. Ennusteita tarkistetaan nykyhetken liikenteen ja muiden tietojen (esim. tietyöt) avulla. Käyttäjäpalvelu www:ssä	Liikennemäärä ja nopeusdataa iduktiosilmukoilta, joita on n. 300 m välein	Internetissä kerrotaan jokaisen päivityypin matka-ajan keskiarvo ja vaihteluväli. Lisäksi muuta tietoa eri reiteistä.		Kehitetty Tokion Metropolitan Expresswayta varten	
10.	Fumitaka Kurauchi, Yasunori Iida, Taku Aizawa	An Evaluation on Effect of Travel Time Information from Real-Time Origin-Destination Matrices Estimation Model. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy. 8 s.	Japani	2000	Tutkia miten liikenne reagoi informaatioon matka-ajoista	Kirjoittajien kehittämä malli, jossa estimoidaan liikennemäärää lähtö-määräpaikkojen välillä (OD-matriisi)	Ramppien ja linkkien liikennemäärät ja linkkien nopeudet	Reitinvaihto-todennäköisyys	OD-matriisin estimointimalli sopii lähinnä moottoriteille	Testattu Hanshinin moottoritieellä Osakan lähellä lokakuussa 1997	
11. Tilasto	Rik van Grol, Domenico Inaudi, Eric Kroes	On-Line Traffic Condition Forecasting Using On-Line Measurements and a Historical Database. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy. 10 s.	Hollanti	2000	Lyhyen ajan ennusteiden tuottaminen	Tilastollinen kehitys täydennettynä reaaliaikaisilla tiedoilla	Tilastotietoa jokaisesta päivityypistä	Liikennemäärä ja nopeus		Testattu moottoriteillä Hollannissa	Reaaliaikaiset liikennetiedot paransivat tuloksia vain vähän. Pidemmän aikavälin ennusteilla reaaliaikaisesta tiedosta ei ollut hyötyä.
13. Tilasto	Billy M. Williams, Brian L. Smith	Traffic Condition Forecasting for ITS Operations. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 8-12 November 1999, Toronto, Canada. 7 s.	USA	1999	Menetelmien ennustetarkkuuden ja helppokäyttöisyyden vertailu liikenne-ennusteiden tuottamisessa	Kausittainen aikasarja-analyysi ja ei-parametrinen regressio	Aikasarjamallille 30 min ja ei-parametrille regressiomallille 15 min liikennemäärä	Liikennemäärä		Aikasarjamalli testattu Ranskasta vuosien 1984-1990 aikana kerätyllä datalla. Ei-parametrinen malli testattu vuonna 1993 kerätyllä datalla.	Molemmat mallit pärjäsivät lähes yhtä hyvin MAPElla mitattuna (mean absolute percent error)

	ENN. MENE- TELMÄ	TEKIJÄ(T)	LÄHDE	MAA	VUOSI	TAVOITE	TOIMINTA	INPUT	OUTPUT	MALLIN RAJOITUKSET	KÄYTÖSSÄ?	TULOKSET
14.	Tilasto, Kalman-suodatust	Masato Iwasaki, Kazuki Saito	Short-Term Prediction of Speed Fluctuations on a Motorway Using Historical Patterns. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 8-12 November 1999, Toronto, Canada. 10 s.	Japani	1999	Liikennetilanteen ennustaminen historiadataan (liikennetilanneluokkien: arki, la, pyhä) ja tämän hetken liikennemittausten perusteella	Liikenne-ennusteet tehdään autoregressiivisella mallilla, jonka parametrien kertoimien määrittämiseen käytetään laajennettua Kalman-suodatusta	5 min liikennemäärä ja keskinopeus	Keskinopeus tietyssä laskentapisteesä	Sopii moottoritille. Mallin on hankala ennustaa yllättäviä tilanteita. Ennusteissa ongelmia etenkin ruuhkan muodostuessa ja alkaessa purkautua.	Testattu Tomein moottoritillä Tokion lähellä	Pidemmällä aikavälillä päästiin parempiin tuloksiin antamalla historiatalle suurempi painoarvo.
15.	Sij + sim	Winfried Kronjäger, Dagmar Hermann	Travel Time Estimation on the Base of Microscopic Traffic Flow Simulation. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 8-12 November 1999, Toronto, Canada. 5 s.	Saksa	1999	Liikennetilanteen ennustaminen mikrosimuloinnin avulla (simulointiohjelma VIDELIO)	Logittimalli reitinvalinnalle	OD-matriisit, tietoa tieverkosta ja liikennevalaisto, tietoa tapahtumista, tiedoista, liikennevirrasta, nykyinen matka-aika	Linkkien matka-ajat ja nopeudet	Sopii kaupunkiverkolle	Testattu Berliinissä 94 km, 50 risteysverkolla	Kehitystyötä reaaliaikaisen datan soveltamisen ja liikenteen sijoittelumallin suhteen on vielä tehtävä.
16.	Tilasto, tekoäly	Yang Zhaozheng, Chu Lianyu	A Study on the Locally-determined Dynamic Route Guidance System in China. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 8-12 November 1999, Toronto, Canada. 9 s.	Kiina	1999	Parhaan mallin valinta kulloisessakin tilanteessa liikennetilanteen ennustamiseen, dynaaminen reitintuontia	Tilastotietoon perustuva malli, jos reaaliaikaista dataa ei ole saatavilla. ARIMA-malli, kun liikennetilanne vakaa. Neuroverkkomalli, kun liikennetilanne muuttuu nopeasti. Ei-parametrinen malli neuroverkon sijaan, jos opetusdatan laatu huono.	Liikennetietoa ilmaisimilta, kameroilta, testiautoista, poliisilta, tilastoista	Linkkien matka-ajat		Testattu Changchun Cityssä	
17.		Laurence R. Rilett, Dongjoo Park, Byron Gajewski	Estimating Confidence Interval for Freeway Corridor travel Time Forecasts. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 8-12 November 1999, Toronto, Canada. 8 s.	USA	1999	Luottamusvälin löytäminen ennustetulle matka-ajalle	Taylorin sarjalla estimoidaan tiejakson matka-ajan ennusteen keskiarvoa ja varianssia linkkien ennustettujen matka-ajan keskiarvon ja varianssin perusteella.	Linkkien ennustetut matka-ajat, eri linkkien matka-aikojen korrelaatio	Luottamusväli reitin keskimääräiselle matka-ajalle		Testattu Houstonissa Texasissa 11 km tieosuudella lokakuussa 1996	Ensimmäisen asteen Taylor-sarja vaikuttaa olevan riittävä arvioimaan ennusteen luottamusväliä
18.	Sij + sim	Rik van Grol, Karel Lindveld, Simonetta Manfredi, Mehdi Danech-Pajouh, Stef A. Smulders, Rik J.M. van Grol, Joe Whittaker	DACCORD: On-Line Travel Time Estimation/Prediction Results. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 8-12 November 1999, Toronto, Canada. 12 s. Evaluation of a Model for the Real-Time Short-Term Prediction of Traffic Conditions on Motorway Networks. Conference Title: Intelligent Transportation: Realizing the Future. Abstract of the Third World Congress on Intelligent Transport Systems. s. 224-225	Hollanti, Italia, Ranska	1999	EU-projekti DACCORDin esittely, matka-aikojen ennustaminen	Ilmaisinvälin ennustaminen: makroskooppinen liikennevirtamalli Statistical Traffic Model (STM) ja Behavioural Traffic Model (BTM), johon kuuluu dynaaminen OD-matriisi ja sijoittelu. Verkko-osan ennustaminen: dynaaminen ennustemalli ja hetkellinen ennustemalli	Liikennemäärä, nopeus, varausaste ja näistä johdetut matka-aika, tiheys ja jonon pituus	Matka-aika		Puutteellisia testejä Pariisissa ja Italiassa moottoritillä sekä Amsterdamin kehätiellä	Testeissä ongelmia ruuhkattomuuden ym. takia. STM heikohko ja riippuvainen monitoroinnista. BTM suoriutui vähän paremmin

ENN. MENE- TELMÄ	TEKIJÄ(T)	LÄHDE	MAA	VUOSI	TAVOITE	TOIMINTA	INPUT	OUTPUT	MALLIN RAJOITUKSET	KÄYTÖSSÄ?	TULOKSET
19. Sij + sim	Darryn Paterson, Geoff Rose	Dynamic Travel Time Estimation on Instrumented Freeways. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 8-12 November 1999, Toronto, Canada. 11 s.	Australia	1999	Makroskooppiseen liikennevirtateoriaan ja deterministiseen jonoteoriaan perustuva soluautomaattimalli (recursive cell processing model) matka-ajan ennustamiseen.	Vapaan virran matka-aikaan lisätään viivytys, joka on saatu mittaamalla erilaisten pullonkaulojen palveluaikaa	Pistenopeuksia ilmaisimilla, pullonkaulojen ja ramppien ym. kuormitusaste (processing rate)	Matka-aika	Mootortietekäyttöön	Testejä 15 km tiejaksolla Melbourneissa	MSE 2,3 Yliarvioi matka-aikaa hieman
20.	Hojung kim, Kyonghee Choi, Byungha Ahn	Evaluation of Estimated Shortest Travel Time in Dynamic Traffic Network Using TRAF-NETSIM. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 8-12 November 1999, Toronto, Canada. 6 s.	Korea	1999	Nopeimman reitin löytäminen	Lyhyin matka-aika estimoidaan parannetulla Dijkstra-algoritmilla (lyhyimmän reitin löytäminen) käyttäen viimeajan matka-aikojen keskiarvoja. Saatua tulosta verrataan simulointitulokseen	Dynaaminen OD-matriisi, nykyinen matka-aika	Reitti, jonka matka-aika on lyhin		Mallin arviointi tehtiin simulointiohjelma TRAF-NETSIMin avulla	
21. Kalman-suodatus, tekoäly, tilasto	Young-lhn Lee, Chan Young Choi	Development of a Link Travel Time Prediction Algorithm for Urban Expressway. Konferenssi-cd, 5th World Congress on Intelligent Transport Systems, 12-16 October 1998, Seoul, Korea. 8 s.	Korea	1998	Kalman-suodattimen, neuroverkkojen ja aikasarjamallin vertailu matka-ajan ennustamisessa		Liikennemäärä, nopeus, varausaste	Nopeus	Kalman suodatinta ja neuroverkkoa rajoittavat datan kerääminen ja mallin siirrettävyys paikasta toiseen.	Testattu Olympic Expresswayn kahden tunnin datalla 1998	Kalman-suodatus osoittautui parhaaksi ennustemalliksi. Kalman suodatus MSE 9.9, ARIMA MSE 10.3, neuroverkko: MSE 13,8
22. Tilasto, tekoäly	Jinsoo You, Tschangho John Kim	Toward Developing an Expert GIS-Based Travel Time Forecasting Model with Congestion Pattern Analysis. Konferenssi-cd, 5th World Congress on Intelligent Transport Systems, 12-16 October 1998, Seoul, Korea. 13 s.	Korea	1998	Tarkastella ennustamiseen käytettyjä menetelmiä ja kehittää niiden pohjalta myös GIS-dataa hyödyntävä malli	Mallissa on mukana paikkatietojärjestelmä (GIS) liikennetietokantoja varten, liikennetilanteet luokitteleva tilastomalli, liikenteen seuranta, datan käsittely ja luokittelu sekä ennusteiden teko (neuroverkot ja ES=expert systems)	Liikennetietoa ilmaisimilla, testiautoista, historiatietokannasta ja poliisilta sekä hätäkeskuksilta	Liikennemäärä ja matka-aika		Ei käytössä	
23. Kalman-suodatus, tekoäly, tilasto	Seungjae Lee, Daehyon Kim, Juyoung Kim, Bunchul Cho	Comparison of Models for Predicting Short-Term Travel Speeds. Konferenssi-cd, 5th World Congress on Intelligent Transport Systems, 12-16 October 1998, Seoul, Korea. 9 s.	Korea	1998	Menetelmiä, joilla ennustetaan pistenopeuksia ja sitä kautta matkanopeuksia	Usean muuttujan regressio, aikasarja-analyysi (ARIMA), neuroverkot, Kalman-suodatus	Kunkin solmun nopeuden ennustamiseen käytetään edellisen ja seuraavan solmun liikennedatata (nopeus, liikennemäärä, varausaste) edelliseltä aika-askeleelta. Data kerätään kuvankäsittelyllä ilmaisimilla a??? (image processing detector)	Pistenopeus		Testattu oikealla liikennedatalla	Selitystason ja MSE:n perusteella neuroverkko ja Kalman-suodatus antoivat parhaat tulokset
24.	Young Wook Park	A Model for Dynamic Traffic Flow Guidance System. Konferenssi-cd, 5th World Congress on Intelligent Transport Systems, 12-16 October 1998, Seoul, Korea. 8 s.		1998	Dynaaminen reitinvalintaohjaus ruuhkien välttämiseen (systeemioptimi)	Autoilijoille lähetetään esim. kännykkään lyhyen ajan ennusteeseen perustuva reitinvalintasuositus ja tietoa nykyisistä liikenneoloista.	Dynaaminen OD-matriisi, reaaliaikainen liikenteen generointidata sekä jokaisen linkin ja reitin nykyinen matka-aika	Reitinvalintaehdotuksia kullekin autoilijalle erikseen		Testattu simuloinnalla	
25.	Satoshi Matsumura, Hitoshi Yamashita, Shusaku Iwaki, Hiroyuki Sugimura	Experimental Verification of Travel-Time Prediction Method. Konferenssi-cd, 5th World Congress on Intelligent Transport Systems, 12-16 October 1998, Seoul, Korea. 8 s.	Japani	1998	Matka-ajan ennustaminen kirjoittajien kehittämällä mallilla	Matka-aika lasketaan joka linkille ja sen jälkeen jokaiselle reitille perustuen tilastoidun ja tämän hetkisen matka-ajan erotukseen	Yleinen matka-aika (mitattiin testiajoneuvolla), tämän hetken matka-aika (automaattinen ajoneuvontunnistus, erilaiset ilmaisimet)	Matka-aika		Testattu Osakan ja Takatsukin kaupungin välillä kahdeksalla reitillä kahdeksan päivän aikana 1997	Matka-ajan ennusteissa virheiden osuus (error rate) 11,4 %.

	ENN. MENE- TELMÄ	TEKIJÄ(T)	LÄHDE	MAA	VOUOSI	TAVOITE	TOIMINTA	INPUT	OUTPUT	MALLIN RAJOITUKSET	KÄYTÖSSÄ?	TULOKSET
26.	Tilasto	Toru Otokita, Kana Hashiba	Travel Time Prediction Based on Pattern Extraction from Database. Konferenssi-cd, 5th World Congress on Intelligent Transport Systems, 12-16 October 1998, Seoul, Korea. 8 s.	Japani	1998	Matka-ajan ennustaminen kirjoittajien kehittämällä mallilla	Matka-aikaa arvioidaan liikennetilanteen perusteella. Ennuste tehdään usean muuttujan regressiolla.	Tietokanta liikennetilanteista, nykyinen matka-aika ja liikennemäärä	Matka-aika		Testattu simuloimalla. (Data kuitenkin oikeaa liikennetietoa Yokohamasta.)	Matka-ajan ennusteissa virheiden osuus (error rate) 7,74 %. Korrelaatiokerroin 0,93
27.		Takeshi Kurokawa, Keiichi Ogawa	A Study on Travel Time Prediction Method on Inter-City Expressways Using Traffic Capacity at the Bottleneck. Konferenssi-cd, 5th World Congress on Intelligent Transport Systems, 12-16 October 1998, Seoul, Korea. 8 s.	Japani	1998	Tuottaa informaatiota ennustetuista matka-ajoista tienkäyttäjille	Keskimääräinen matka-aika ennustetaan erikseen ruuhkaantuneelle ja vapaalle virralle ajoneuvojen määrän ja pullonkaulan välityskyvyn avulla	Ajoneuvojen määrä kullakin tieosuudella, pullonkaulan välityskyky, nopeus, liikennemäärä ja -tiheys sekä tiegeometria	Matka-aika		Testattu Tomein moottoritillä yhden päivän aikana 1995	Korrelaatiokerroin 0,96
28.	Tekoäly	Youngchan Kim, Daeho Kim, Do Gyeong Kim	Estimation of Link Travel Time Using Vehicular Detection Develces in TRACS (TRaffic Adaptive Control System). Konferenssi-cd, 5th World Congress on Intelligent Transport Systems, 12-16 October 1998, Seoul, Korea. 8 s.	Korea	1998	Esitellä TRACS-systeemin avulla tehtäviä matka-aikaennusteita	Tietoa liikenteestä TRACS-järjestelmän avulla. Ennustemallit sumeaaan logiikkaan ja neuroverkkoihin perustuen	Liikennemäärä ja ilmaisimen varausaste ja näistä johdettu nykyinen matka-aika	Sumeaa logiikkaa käytävässä mallissa matkanopeus ja neuroverkkomallissa matka-aika	TRACS on valo-ohjauksen hallintaan tarkoitettu ohjelma	Testattu Souliissa	Neuroverkko: MSE 8,7-13 sumea logiikka MSE 20,6-38,2. Ennusteet paranivat kun käytettiin useampaa ilmaisinta.
29.	Tekoäly	Haibo Chen, Mark Dougherty, Howard Kirby	An Investigation of Detector Spacing and Forecasting Performance Using Neural Networks. Konferenssi-cd, 4th World Congress on Intelligent Transport Systems, 21-24 October 1997, Berlin, Germany. 7 s.	Britannia	1997	Ilmaisimien optimaalinen sijoittaminen neuroverkoilla tehtyjen lyhyen ajan ennusteiden kannalta	Ilmaisimien sijoittelua arvioitu sekä simuloimalla että oikealla maastoaineistolla					Ilmaisimien ihanteellinen välimatka on n. 1 km. Tiheämmällä sijoittelulla ei useinkaan saavuteta suurta hyötystä kustannuksiin nähden.
30.	Tilasto	Wolfgang Schober, Matthias Glatz	Accessing the Potential of Short-Term-Prediction in a Dynamic Route Guidance System by Evaluating its Floating Car Data. Konferenssi-cd, 4th World Congress on Intelligent Transport Systems, 21-24 October 1997, Berlin, Germany. 8 s.	Saksa	1997	Vertailla pelkän historiadatan pohjalta tehtyjä matka-aikaennusteita vertailupäivien tietojen avulla tehtyihin ennusteisiin	Kunakin reitin matka-aika ennustetaan sekä tilastotietojen että vertailupäivien tietojen perusteella.	Tilastotieto eri viikonpäivistä, tilannekirjastot	Reittisuositus		Testattu Berliinissä 650 instrumentoidulla ajoneuvolla	Normalitilanteessa 2-4% matka-ajan säästö vertailupäiviä käyttäen.
31.	Tilasto	Masato Iwasaki, Masuo Kotani, Kazuki Saito	Classification of Historical Mean Speed Pattern on a Motorway for Prediction of Near-Future Traffic Flow States. Konferenssi-cd, 4th World Congress on Intelligent Transport Systems, 21-24 October 1997, Berlin, Germany. 6 s.	Japani	1997	Tutkia, miten historiadata voitaisiin ryhmitellä lyhyen ajan ennusteiden laatimiseksi ja erityisesti ruuhkatilanteiden ennustamisessa.	Vaihtoehtoina luokitella data vuosittaisen 5 min nopeuden keskiarvon, päivityypin (arki, la, pyhä), säätötyypin tai liikenneolojen (ruuhka, vapaa virta) mukaan	Liikennemäärä, raskaan liikenteen määrä, keskinopeus ja ilmaisimen varausaste				Ennusteita voitaisiin parantaa suodattamalla (smoothing), painottamalla uusia havaintoja ja päivittämällä tietokantaa
33.		Leonid Engelson	Recursive Forecasts of Travel Time for Congested Networks. Konferenssi-cd, 4th World Congress on Intelligent Transport Systems, 21-24 October 1997, Berlin, Germany. 7 s.	Ruotsi	1997	Rekursiivisten ennusteiden periaatteiden tarkastelu	Malli, joka ottaa huomioon kuljettajien reaktiot matka-aikaennusteisiin. Tienkäyttäjille on kerrottava mallin rekursiivisuudesta, siis että heidän ei tarvitse huomioida toisten tienkäyttäjien reaktiota ennusteeseen vaan se on otettu huomioon mallissa. Mallit tienkäyttäjien käyttäytymiselle ja liikenneverkon toimintaa varten.	Käyttäytymismalli: ennakoitu matka-aika, tienkäyttäjien ominaisuudet (reagoiminen liikenne-ennusteisiin). Liikenneverkko: Autojen jakautuminen eri reiteille.	Käyttäytymismalli: autojen jakautuminen eri reiteille. Tämän perusteella liikenneverkkomalli ennustaa matka-aikaa kullakin reitillä.	Isoilla verkoilla monidimensioinen epälineaarinen systeemi, jonka ratkaiseminen vaikeaa.	Ei käytössä.	

	ENN. MENE- TELMÄ	TEKIJÄ(T)	LÄHDE	MAA	VOOSI	TAVOITE	TOIMINTA	INPUT	OUTPUT	MALLIN RAJOITUKSET	KÄYTÖSSÄ?	TULOKSET
34.		Jean-Marc Morin, Joel Bomier, Raymond Fevre	Travel Times on Inter-Urban Motorways: On-Line Estimation and Drivers Information Needs. Some Results in France. Konferenssi-cd, 4th World Congress on Intelligent Transport Systems, 21-24 October 1997, Berlin, Germany. 7 s.	Ranska	1997	Matka-aikojen ennustaminen kolmella eri mallilla, tienkäyttäjien tietotarpeet	Kolme eri estimaattia todelliselle tienkäyttäjän kokemalle matka-ajalle: TPI=hetkellinen matka-aika (oletetaan, että liikennetilanne pysyy muuttumattomana) TPR=rekonstruoitu matka-aika (hetkellä t perille saapuvien matka-aika) TPP=ennustettu matka-aika. Kolme ennustemallia: analyyttinen malli, simulointimalli (MITHRA/SIMRES) ja varastomalli.	Analyyttinen malli: Induktiosilmukoilla 6 minuutin tiedot liikennemäärästä, nopeudesta ja varausasteesta. Testialueilla ilmaisimet n. 9 km välein.	Matka-aika	Samat mallit eivät välttämättä sovi erityyppisille teille (matkan pituus ja tarkoitus sekä ilmaisimien ja muuttuvien opasteiden sijoitus ovat erilaisia)	Testattu Ranskassa	Kaupunkoja yhdistävillä teillä ei tarvita yhtä tarkkoja matka-aikaennusteita kuin kaupunkien tienvierillä. Analyyttinen malli: TPI epävakaa ja ennusteet huonoja, TPR keskivirhe 10 %. Simulointimalli: TPR keskivirhe 20 %, TPP keskivirhe 25-30 %.
35.		Akira Miyata, Kiyotaka Muraoka, Takasama Akiyama, Atsushi Abe	The Correction of the Forecasting Travel Time by Using AVI Data. Konferenssi-cd, 4th World Congress on Intelligent Transport Systems, 21-24 October 1997, Berlin, Germany. 7 s.	Japani	1997	Perinteisillä ilmaisimilla kerätyn liikennetiedon avulla ennustettujen matka-aikojen korjaaminen automaattisen ajoneuvon tunnistamisen avulla	Ajoneuvot tunnistetaan automaattisesti rekisterien perusteella. Matka-ajoneuvotunnistuksella mitattuna.	Nopeus ilmaisimien avulla ja automaattisella ajoneuvotunnistuksella mitattuna.	Matka-aika ja liikennemäärä tulo- ja poistumisrampien välillä.	Ongelmia ajoneuvojen automaattisessa tunnistamisessa, koska koko rekisteritunnusta ei lueta (kaksi eri autoa voidaan sekoittaa keskenään)	Testattu Hanshinin moottoritievierillä	
36.	Sij + sim	Jean-Marc Morin, Bernard Baradel, Joel Bomier	On-Line Short Term Simulation and Forecast of Motorway Traffic Patterns: Field Results Obtained on ASF Network in France. 3th World Congress on Intelligent Transport Systems, 14-18 October 1996, Orlando, USA. 9 s.	Ranska	1996	Liikennetilanteiden ennustaminen	OD-matriisin ennustaminen (MITHRA) ja liikennevirran makroskooppinen simulointi (SIMRES)	MITHRA tarvitsee usean vuoden OD-matriisit (liikennelaskennat) ja tämän hetken liikennemäärän lähtötiedoiksi. SIMRES tarvitsee reaaliaikaista mittaus tietoa liikennemäärästä, nopeudesta ja varausasteesta. Data kerättiin 49:ssä mittauspisteessä	Liikennetilanneluokkaa (värikoodattu kartta). Rinnakkain esitetään nykytilanne ja ennustettu liikennetilanne (2 tunnin päästä).		Testattu moottoritieillä Ranskassa kesällä 1995 välillä Vienne-Montpellier/Lancon	Liikennemäärän 2 tunnin ennusteen suhteellinen neliökeskivirhe (MRQE = mean relative quadratic error) 24-28 %
38.	Tilasto	Matthew P. D'Angelo, Haitham M. Al-Deek, Morgan C. Wang	Travel-Time Prediction for Freeway Corridors. Transportation Research Record, No. 1676. s. 184-191.	USA	1999	Matka-aikojen ennustaminen liikenneinformaatiota varten	Sekä yhden muuttujan (nopeus) että usean muuttujan (nopeus, liikennemäärä, varausaste) epälineaarinen aikasarjamalli	Induktiosilmukoilla tiedot nopeudesta liikennemäärästä ja varausasteesta 30 s välein	Nopeuden ja sitä kautta tiejakson matka-ajan ennuste 5 min välein.	Puutteita liikenneolojen muuttuessa eli ruuhkan syntyessä ja purkauessa. Ei ole testattu onnettomuustilanteissa.	Testattu Orlandossa Floridassa 18 km tiejaksoilla	Yhden muuttujan malli: 98% ennusteista 10% virhemarginaalin sisällä. Virhettä eniten ruuhkan syntyessä ja purkauessa. Yhden muuttujan malli suoriutui paremmin kuin usean muuttujan malli.
39.	Tilasto, tekoäly	Dongjoo Park, Laurence R. Rilett	Forecasting Multiple-Period Freeway Link Travel Times Using Modular Neural Networks. Transportation Research Record, No. 1617. s. 163-170.	USA	1998	Matka-aikojen ennustaminen liikenneinformaatiota varten	Tilastoidut matka-ajat jaetaan luokkiin valvomaton ryhmittelyteknikkaa (itseorganisova kartta ja sumea logiikka (fuzzy c-means clustering)) käyttäen ja jokaiselle luokalle luodaan oma neuroverkko matka-aikojen ennustamista varten	Linkkien matka-ajat, jotka kerätään automaattisen ajoneuvon tunnistuksen avulla	Linkkien matka-ajat seuraaville 5-25 minuutille	Huomioitava ryhmittelyyn käytettävät parametrit ja niiden painoarvot, ryhmien ominaisuuksien erotelu (feature extraction)	Testattu Houstonissa Texasissa 27,6 km tiejaksoilla. Dataa kerätty vuoden ajan.	Sumeaa logiikkaa käyttävä ryhmittelyteknikka antoi hieman parempia tuloksia kuin SOM. Ennustevirhe sumea logiikkaa käyttäen 8,1-15,7 % (kasvaa ennustejakson pituuden kasvaessa)

	ENN. MENE- TELMÄ	TEKIJÄ(T)	LÄHDE	MAA	VOUOSI	TAVOITE	TOIMINTA	INPUT	OUTPUT	MALLIN RAJOITUKSET	KÄYTÖSSÄ?	TULOKSET
40.	Tekoäly	Satu Innamaa	Short-Term Prediction of Highway Travel Time Using MLP-Neural Networks. 8th World Congress on Intelligent Trasport Systems, 30 Sept. - 4 Oct. 2001. Sydney, Australia. 12 s.	Suomi	2001	Selvittää, minkälaisilla syötteillä saadaan aikaiseksi paras matka-aikaennuste ja miten järjestelmän rakenne vaikuttaa ennusteeseen.	Kullekin osalinkille ja osalinkkiyhdistelmälle oma neuroverkko.	Korrelaation perusteella valittuja eri linkkien erilaisia keski- ja mediaanimatka-aikoja sekä matka-ajan keskihajontoja (kamerat, automaattinen ajoneuvon tunnistus) sekä liikennemääriä, keskinopeuksia ja keskihajontoja (LAM-pisteet)	Matka-aikaennuste kullekin osalinkille ja osalinkkiyhdistelmällä seuraavan minuutin aikana saapuville ajoneuvoille		Testattu vt4:llä välillä Lahti-Heinola	Paras malli ennusti oikein 90% ajasta ruuhkaliikenteessä. Mallien hyvyyttä vaihteli suunnan ja sen mukaan, oliko linkki jaettu osalinkkeihin vai ei. Malli yllärvioi matka-aikoja hieman.
41.	Tilasto	Nick Hounsell, Saeed Ishtiaq	Journey Time Forecasting for Dynamic Route Guidance Systems. Proceedings of the Second DRIVE-II Workshop on Short-Term Traffic Forecasting, 1994/11 (Report inro-vvg 1994-19). s. 1-18.	U.K.	1994	Ennustaa matka-aika sekä häiriötilanteissa	Normaaleissa olosuhteissa aikasarjamallit (Holt-Winters, Kalman-suodatus, Box-Jenkins, Berliinin LISB). Häiriötilanteissa häiriö paikannetaan ja sen kesto ja vakavuus arvioidaan. Ennustetaan, mihin linkkeihin häiriö vaikuttaa ja ennustetaan näiden matka-ajat häiriön vakavuuden perusteella. Uuden mittauksen perusteella arvioidaan, onko tilanne normalisoitunut.	CONTRAMI-simulointiohjelmalla koottu tietokanta häiriötilanteista, tietoa liikennetilanteesta tietyin väliajoin	Linkin matka-aika		Mallia testattu vertaamalla ennustettuja tuloksia simuloimalla saatuihin tuloksiin	Normaaleissa olosuhteissa parhaiten toimi Kalman-suodatus. Häiriötilanteissa matka-aikaennusteissa MAPE 47-68% (malli yllärvioi matka-aikaa). Ennustettaessa linkkien määrää, joihin häiriö vaikuttaa, MAPE oli 31-55%. Virheprosentti aleni, kun ennustetta korjattiin mittaus tuloksiin (matka-aika edellisellä aika-askeleella) perustuen.
42.	Tilasto	Filippo Logi, Dieter Wild, Dieter Wild	An Intelligent Predictor for Urban Traffic. Pattern-Based Forecasting. Proceedings of the Second Meeting of the Euro Working Group on Urban Traffic and Transportation, 15-17 September 1993, Paris, France (Actes Inrets no 38). 1994/04. S. 83-109.	Saksa	1994	Lyhyen ajan ennusteiden tuottaminen tilastotiedon pohjalta	Liikennetilanteet luokitellaan viikonpäivän ja muiden ympäristömuuttujien mukaan ja ennusteet tehdään vertaamalla nykytilannetta näihin luokkiin.	Liikennemäärä	Liikennemäärä halutuilla linkeillä	Sopii kaupunkiverkolle ja kaupunkien välille. Ennusteiden onnistuminen riippuu tietokannan täydellisyydestä (kaikki eri tilanteet mukana), ryhmittelyn onnistumisesta ja ruuhkan toistuvuudesta.	Testattu Kölnissä 1993 ja 1994 kerätyllä datalla.	Pidempiä aikavälillä (yli 15 min) ennusteilla kehitetty malli ennusti paremmin kuin vertailuna käytetyt triviaali- (tietokannan keskiarvoon perustuva) ja liukuva keskiarvo - malli. RMSE 2.8-4.9 (4,5 min - 1 h).
43.		Y.S. Chen, H.J.M. van Grol, Ch.D.R. Lindveld, P. Mijjer, S. Smulders	Link/Network Performance Models: Results in DYNA. Proceedings of the Second DRIVE-II Workshop on Short-Term Traffic Forecasting, 1994/11 (Report inro-vvg 1994-19). s. 153-74.	Hollanti	1994	Lyhyen ajan liikenne-ennusteiden tuottaminen, erityisnäkökulma verkkotasolla	Ruuhkan todennäköisyyttä arvioidaan liikennemäärän tai tiheyden perusteella ja huomioidaan kapasiteetin aleneminen ruukan takia	250 mittauspistettä, joilta saadaan liikennemäärä ja nopeus sekä näistä johdettu liikennetiheys	Nopeus, ruuhkan todennäköisyys	Sopii keskikokoiselle verkolle.	Testattu Rotterdamin ympäristössä toukokuussa 1994	Ruuhkattomana aikana ennusteessa on viivettä. Ennusteet olivat kuitenkin hieman parempia ruuhkattomana aikana kuin ruuhkassa.

	ENN. MENE- TELMÄ	TEKIJÄ(T)	LÄHDE	MAA	VUOSI	TAVOITE	TOIMINTA	INPUT	OUTPUT	MALLIN RAJOITUKSET	KÄYTÖSSÄ?	TULOKSET
44.	Tilasto, sij + sim	Ch.D.R. Lindveld, E.P. Kroes, H. de Ruiter	DYNA; Real Time Congestion Prediction. Colloquium Vervoersplanologisch Speurwerk 1992. Innovatie in Verkeer en Vervoer. 26-27 November 1992, Rotterdam. Deel III. s. 875-893.	Hollanti	1992	Liikennetilanteiden ja matka-aikojen ennustaminen kaupunkien välisellä moottoritieverkolla	Tilastollinen malli (STA) liikennedatan suodatukseen ja hyvin lyhyen ajan (1-15 min) ennusteiden tekoon. Dynaaminen liikenteen sijoittelumalli (DTA) lyhyen ajan (15-60 min) ennusteiden tekoon. Reaaliaikainen OD-matriisin estimointimalli (ODME)	Liikennemäärä, keskinopeus ja varausaste kultakin minuutilta. Ilmaisimien välimatkat n. 3 km. Tilastotietoa liikenteestä (tilastoidut OD-matriisit), tietoa liikenneverkon infrastruktuurista, tietoa onnettomuuksista, tietöistä, tapahtumista jne.	Linkkikohtainen tieto liikennemäärästä, matka-ajasta ja ruuhkasta (on/ei)	STA sopii vain hyvin lyhyen ajan ennusteisiin, koska se ei ota huomioon autoilijan reitinvalintaa. DTA tekee ennusteen hitaasti ja vaatii OD-matriisin lähtötiedoikseen.	Testataan Rotterdamin ympäristössä.	
45.			http://www.sytadin.tm.fr/	Ranska	2001	Matka-aikojen estimoinnin, liikenneindeksi SIER	Mittausten perusteella arvoidaan onko liikenne keskimääräistä vai tavallista vilkkaampaa tai vähäisempää. SIER-indeksi kertoo, kuinka paljon vapaasta virrasta poiketaan.	Liikennetiedot (nopeus, liikennemäärä) 6 minuutin välein 3000 laskentapisteltä, jonka perusteella lasketaan "liikennetilanne-luokka" (SIER-index). Tietokanta SIER-indeksin arvosta ja vaihteluista useilta kuukausilta.	Tieto siitä, onko liikenne keskimääräistä, vähäisempää, vilkkaampaa, erittäin paljon vilkkaampaa vai poikkeuksellista		Käytössä Pariisin alueen päätieverkolla	
46.	Tilasto, tekoaly	Pawan Lingras, Satish C. Sharma, Phil Osborne, Iftekhar Kalyar	Traffic Volume Time-Series Analysis According to the Type of Road Use. Computer-Aided Civil and Infrastructure Engineering, 2000/09, s. 365-373.	Kanada	2000	Neuroverkon ja autoregressiomallin käyttö liikennemäärän ennustamisessa.	Tiet on jaettu viiteen tyyppiin matkan tarkoituksen (loma- ja työmatkojen osuus) ja matkojen pituuden mukaan ja kaikille luokille on tehty oma malli.	Liikennemäärä	Kolmentoista edellisen päivän liikenteen perusteella ennustettiin seuraavan päivän liikennemäärä.		Testattu Albertassa	Neuroverkoennusteet onnistuivat autoregressiomallia paremmin. Ennusteet onnistuivat paremmin säännöllistä työmatkaliikennettä välittävillä teillä. Keskimääräinen virheiden osuus (error rate) oli autoregressiomallilla 6.39-15.62 % ja neuroverkolla 5.87-13.53 %. Maksimivirheet olivat 228 % ja 164 %, mutta 95 %:n virheet olivat 15-45 % luokkaa.
47.	Sij + sim	F. Meissner, M. Cremer	The Role of Macroscopic Simulation for Proper Route-Guidance Decisions. Proceedings of the Prometheus Workshop on Traffic Related Simulation, December 1992, Stuttgart. s. 38-53.	Saksa	1992	Lyhyen ajan ennusteet reittineuvontaa varten	Ennusteet tehdään makroskooppisella simulointimallilla SIMONElla (Simulation of Motorway Networks)	Liikennetiheys, keskinopeus, liikennemäärä jokaiselle simulointimallin tiejaksoilla (joiden pituus on 300-600m)	Kokonaismatka, kokonaismatka-aika, kokonaisviivytys, yksittäisen reitin matka-aika ja polttoaineen kulutus			Reittipastus kannattaa tehdä käyttäjäoptimin näkökulmasta, koska tällöin autoilijat kokevat opastuksen hyödylliseksi. Joissain tilanteissa käyttäjäoptimi voi johtaa ongelmiin ja tämän takia reittipasteita täytyy kontrolloida myös systeemioptimin avulla.
48.	Tilasto		Traffic Control and Communication Centre, Leading the way in traffic management. VicRoads. Sähköpostitiedustelu Steve Beanilta VicRoadsilta. VicRoadsin Internet-sivut http://www.vicroads.vic.gov.au/	Austaralia	2001	Matka-aikojen ennustaminen liikenneinformaatiota varten	Matka-aikoja moottoritieosuuksilla estimoidaan mitattuun liikennemäärään ja nopeuteen perustuen. Matka-ajat esitetään liittymäväleittäin infotauluilla, joilla tiedotetaan myös onnettomuuksista, tietöistä ja huonosta kelistä. Värikoodilla kerrotaan myös onko liikennettä tavallista enemmän tai vähemmän.	Liikennemäärä ja nopeudet induktiosilmukoilta ja videokameroista. Tietoa kerätään 500-750 m välein.	Matka-aika kullekin liittymävälillä		Toiminut Australiassa Melbournen ympäristössä maaliskuusta 1998.	Matka-aikainformaatiossa pyritään alle kahden minuutin tarkkuuteen ja usein tulokset ovat tätä parempia.

ISSN 1457-9871
ISBN 951-726-829-7
TIEH 3200719